

UNIVERSIDADE FEDERAL DO PARANÁ

GABRIEL HENRIQUE DE ALMEIDA PEREIRA

AVALIAÇÃO DO USO COMBINADO DE MÉTODOS DE MODELAGEM DA
DIREÇÃO DO ESCOAMENTO SUPERFICIAL E MODELOS DIGITAIS DE
SUPERFÍCIE DERIVADOS DE *LASER SCANNER* EM REGIÕES URBANAS

CURITIBA

2013

GABRIEL HENRIQUE DE ALMEIDA PEREIRA

AVALIAÇÃO DO USO COMBINADO DE MÉTODOS DE MODELAGEM DA
DIREÇÃO DO ESCOAMENTO SUPERFICIAL E MODELOS DIGITAIS DE
SUPERFÍCIE DERIVADOS DE *LASER SCANNER* EM REGIÕES URBANAS

Projeto de Dissertação apresentado ao Programa de
Pós-Graduação em Engenharia de Recursos Hídricos
e Ambiental, Setor de Tecnologia da Universidade
Federal do Paraná, como requisito parcial à obtenção
de grau de Mestre.

Orientador: Prof. Dr. Jorge Antonio Silva Centeno

CURITIBA

2013



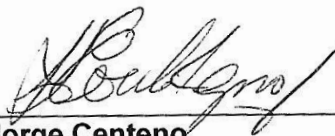
TERMO DE APROVAÇÃO

Gabriel Henrique de Almeida Pereira

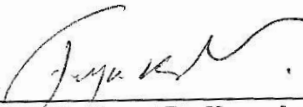
“Avaliação do Uso Combinado de Métodos de Modelagem da Direção do Escoamento Superficial e Modelos Digitais de Superfície Derivados de Laser Scanner em Regiões Urbanas”

Dissertação aprovada como requisito parcial à obtenção do grau de Mestre, pelo Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental do Setor de Tecnologia da Universidade Federal do Paraná, pela comissão formada pelos professores:

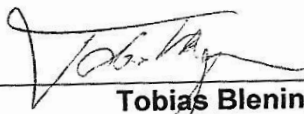
PRESIDENTE:


Jorge Centeno
Universidade Federal do Paraná
Orientador

MEMBROS:


Alzir Felipe Buffara Antunes
Universidade Federal do Paraná


Claudia Pereira Krueger
Universidade Federal do Paraná


Tobias Bleninger
Universidade Federal do Paraná

Curitiba, 25 de fevereiro de 2013

AGRADECIMENTOS

Ao CNPq, pelo apoio financeiro.

Às empresas CetilGeo, Esteio Engenharia e Aerolevantamentos e Instituto de Tecnologia para o Desenvolvimento – LACTEC, que cederam os dados utilizados nesta pesquisa.

Ao orientador prof Dr. Jorge Antonio Silva Centeno, por sua orientação, sempre disposto a esclarecer dúvidas, também pelas conversas e incentivos.

Ao Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Ambiental.

Ao Departamento de Geomática e ao prof. Dr. Álvaro Muriel Lima Machado, por terem cedido o computador para processamento da classificação por SVM.

Aos professores que contribuíram diretamente para minha formação acadêmica, como a prof Dr^a. Cynara de Lourdes da Nóbrega Cunha e prof. Dr. Eloy Kaviski, aos quais tenho profunda admiração.

Aos meus orientadores dos trabalhos de conclusão de curso, Prof Dr^a Sony Cortese Caneparo, da UFPR, e prof Dr. Pedro Ramos da Costa Neto, da UTFPR. E, também, aos grandes orientadores profissionais, Prof Dr. Luiz Alkimin de Lacerda e Comandante Luís Miguel Bessa Pacheco, que, com certeza, tiveram papel essencial na minha formação profissional e pessoal, e os considero como grandes exemplos.

Aos colegas e amigos feitos desde a época de colégio, passando pelos de faculdade, até os mais recentes, da época de mestrado, que também tiveram seu papel na minha formação, seja estudando, discutindo teorias ou filosofias em uma mesa de bar!

E, por fim, mas não menos importante, às pessoas que estão diretamente relacionadas ao que sou e que acompanharam ativamente este período de mestrado. Primeiro, seguindo uma ordem cronológica, aos meus pais José Adolpho e Lourdes, que sempre me deram todo o carinho do mundo, educação, incentivos e apoio. Também, à minha namorada Thalita, que encontrei mais recentemente, e que já tem papel fundamental em minha vida!

E depois de amanhã vai chover
E não há nada que Homo não Sapiens
Não há nada que Homo não Sapiens responder

(Confraria da Costa - Homo Tudo Sapiens)

RESUMO

Com a impermeabilização do solo e alterações no meio, o ciclo hidrológico vêm sofrendo alterações significativas, sobretudo, no que diz respeito ao escoamento superficial sobre áreas urbanas. Com isso, existe um aumento no risco de cheias, principalmente pela falta de capacidade de drenagem das redes pluviais, assim como o problema de poluição através do escoamento superficial. Para que se possam definir medidas para mitigar tais eventos, é necessária a identificação dos lugares de maior influência. Com a possibilidade de se obter modelos digitais mais detalhados da superfície, como os obtidos por meio dos dados de *Laser Scanner*, pode-se utilizar tais informações para o melhor entendimento dos processos envolvidos nestes eventos em determinada área. Assim, foi estudada uma metodologia para simulação de escoamento superficial em ambientes urbanizados, utilizando dados altimétricos e imagens de alta resolução, visando identificação de regiões que possam receber maior quantidade de fluxo de escoamento ou poluição. Foram utilizados e comparados métodos de filtragem de dados do *Laser Scanner* para a geração de Modelo Digital de Terreno (MDT) e Modelo Digital de Superfície Normalizado (MDSn); assim como Classificadores Digitais de Imagem, baseados em Inteligência Artificial, avaliando também diferentes tamanhos de amostras de treinamento variados; e algoritmos de simulação da direção do escoamento superficial, sobre duas áreas de estudo. Os métodos de filtragem apresentaram acertos e erros em maior ou menor grau, uma vez que alguns filtraram excessivamente, corrompendo dados do terreno, ou deixando dados que deveriam ter sido filtrados. Os classificadores apresentaram acertos globais elevados, todos com mais de 80% de acerto e a maioria dos testes com acerto global acima de 95%. Foi identificado também que os algoritmos de simulação da direção do escoamento superficial apresentam resultados diferentes entre si, sendo também dependentes dos dados do modelo digital que os alimentam, variando em função da presença ou não de feições que supostamente eram obstáculos ao escoamento superficial.

Palavras-chave: *Laser Scanner*, Imagens de Alta Resolução, Métodos de Filtragem, Classificação Digital de Imagens, Algoritmos de Determinação da Direção do Escoamento Superficial.

ABSTRACT

Soil imperviousness and environmental changes introduce severe changes in the water cycle, especially in urban areas. This can lead to increasing risk of flooding, mainly because the drainage networks are overloaded. Pollution is also increased and spread, as the surface runoff increases. It is necessary to develop solutions to identify locals where the risk is higher and develop methods to reduce this risk. An essential information to manage such situations is the knowledge of the topography in order to simulate runoff. Nowadays, remote sensing is able to provide altimetry from satellites and such models are used to model runoff in big basins. A more detailed description can be obtained using laser scanner data, but methods to handle with such detailed information are still not being considered. This work deals with the problem of runoff modelling in urban environments using laser scanner data and high-resolution images. The aim is to identify regions that can accumulate large volume of runoff and diffuse pollution. Different methods to filter laser scanner data, for the generation of Digital Terrain Model (DTM) and Digital Surface Model Normalized (DTMn) were compared and evaluated. In order to suppress vegetation, image classification was applied. Two methods based on artificial intelligence were compared. Then, the runoff was modelled applying different flow direction algorithms in two study areas within the city of Curitiba. According to the experiments, the DTM extraction based on mathematical morphology was more successful and the neural networks approach proved to be more efficient. When analysing the flow directions, that can be used to model urban runoff, it was verified that the single direction approaches lead to bad results. The methods that are based on multiple paths produced better results and are similar in terms of processing time. A significant contribution of this work is showing the necessity to perform a selective elimination of obstacles, because some elements, like treetops or power transmission network may introduce severe changes in the flow paths, while buildings and wall need to be preserved, because their influence on flow paths is real.

Keywords: Laser Scanner, High Resolution Images, Filtering Methods, Digital Image Classification, Flow Direction Algorithms.

LISTA DE FIGURAS

Figura 1 – (a) Representação de um caso de terreno acidentado, (b) e a mesma situação após normalização.....	24
Figura 2 – Representação gráfica de uma Rede Neural Artificial.	30
Figura 3 - (a)Vários hiperplanos que podem separar as classes, (b) hiperplano ótimo (KAVZOGLU e COLKESEN, 2009).	36
Figura 4 - Esquema do cálculo do fluxo realizado pelo D8, MS, DInfinito.	46
Figura 5– Localização das Áreas de Estudo.....	50
Figura 6 – Informação espectral do Campus Centro Politécnico – UFPR (a) combinação do visível (b) combinação com infravermelho.	52
Figura 7 - Dados de altimetria do <i>Laser Scanner</i> do Campus Centro Politécnico – UFPR.....	53
Figura 8 - Intensidade de retorno do <i>Laser Scanner</i> do Campus Centro Politécnico – UFPR.....	53
Figura 9 - Imagem da região do espectro do visível de parte dos bairros Água Verde / Rebouças – Curitiba –PR – BR.	54
Figura 10 - Dados <i>Laser Scanner</i> de altimetria de parte dos bairros Água Verde / Rebouças – Curitiba –PR – BR.	55
Figura 11 - Intensidade do retorno do pulso do <i>Laser Scanner</i> de parte dos bairros Água Verde / Rebouças – Curitiba –PR – BR.	55
Figura 12 – Fluxograma da metodologia deste trabalho, com a descrição dos métodos de filtragem, classificadores e algoritmos de simulação de escoamento utilizados.	56
Figura 13 – Esquema de funcionamento do método de pirâmide.	61
Figura 14 - Representação do plano e margens obtidos no treinamento do SVM (KAVZOGLU e COLKESEN, 2009)	69
Figura 15 - Representação da variável de folga (KAVZOGLU e COLKESEN, 2009) .	70

Figura 16 - Mapeamento dos conjuntos de dados para o de maior dimensão com uma função Kernel (KAVZOGLU e COLKESEN, 2009).	71
Figura 17 - Oito facetas triangulares planas são formadas entre o pixel e os seus oito vizinhos (adaptado de TARBOTON, 1997).	77
Figura 18 - Cálculo da declividade do método Dinfinite (TARBOTON, 1997).	77
Figura 19 – Dados de altimetria do <i>Laser Scanner</i> do Campus Centro Politécnico, organizados em formato <i>raster</i> , sem tratamento prévio.	81
Figura 20 – Dados de altimetria do <i>Laser Scanner</i> do Campus Centro Politécnico, após operação de fechamento.	81
Figura 21 – Dados de altimetria do <i>Laser Scanner</i> do Campus Centro Politécnico, após operação de fechamento, seguida da operação de abertura.	82
Figura 22 – Dados de altimetria do <i>Laser Scanner</i> do Campus Centro Politécnico, após verificação de pixels sem informação.	83
Figura 23 – Modelos Digital de Superfície em 3 dimensões, gerados a partir dos dados de altimetria do <i>Laser Scanner</i> , do Campus Centro Politécnico.	83
Figura 24 – Dados de altimetria do <i>Laser Scanner</i> de parte do bairro Água Verde / Rebouças, organizados em formato <i>raster</i> , sem tratamento prévio.	85
Figura 25 – Dados de altimetria do <i>Laser Scanner</i> de parte do bairro Água Verde / Rebouças, após operação de fechamento.	85
Figura 26 – Dados de altimetria do <i>Laser Scanner</i> de parte do bairro Água Verde / Rebouças, após operação de fechamento, seguida da operação de abertura.	86
Figura 27 – Detalhe da remoção de feições como redes de transmissão de energia após a operação de abertura.	86
Figura 28 – Dados de altimetria do <i>Laser Scanner</i> de parte do bairro Água Verde / Rebouças, após verificação de pixels sem informação.	87
Figura 29 - Modelo Digital de Superfície em 3 dimensões gerado a partir dos dados de altimetria do <i>Laser Scanner</i> de parte dos bairros Água Verde / Rebouças – Curitiba –PR – BR.	88

Figura 30 – Faixa de dados com informação espectral e de <i>Laser Scanner</i> para parte do bairro Água Verde / Rebouças.....	89
Figura 31 – Filtragem dos Dados <i>Laser Scanner</i> para a Área do Centro Politécnico.	90
Figura 32 - – Filtragem dos Dados Laser Scanner para a Área da Água Verde / Rebouças.	90
Figura 33 – Resultados dos Métodos de Filtragem para a área do Centro Politécnico (a) Morfologia Matemática ALDPAT, operador circular; (b) Morfologia Matemática, operador linear; (c) ETEW ALDPAT; (d) Morfologia Matemática, operador quadrado.	92
Figura 34 – Resultado do Método de Filtragem de Morfologia Matemática, operador quadrado, para a Área da Água Verde / Rebouças.	94
Figura 35 – Modelo Digital de Superfície Normalizado, utilizando o método de filtragem de morfologia matemática, operador circular, da área do Centro Politécnico.	96
Figura 36 – Modelo Digital de Superfície Normalizado, utilizando o método de filtragem de morfologia matemática, operador quadrado, da área da Água Verde / Rebouças.	96
Figura 37 - Acertos Globais da RNA, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área do Centro Politécnico.	102
Figura 38 - Acertos Globais da RNA, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área da Água Verde / Rebouças (a) com valores do Método de Filtragem de Formação de Pirâmide; (b) sem valores do Método de Filtragem de Formação de Pirâmide.	102
Figura 39 - Acertos Globais do SVM, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área do Centro Politécnico.	106
Figura 40 - Acertos Globais do SVM, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área da Água Verde / Rebouças.	106
Figura 41 – Modelo Digital de Superfície do Centro Politécnico, após a filtragem das árvores, utilizando o método de formação de Pirâmide e SVM com treinamento de 50% das amostras.....	109

Figura 42 - Modelo Digital de Superfície da área da Água Verde / Rebouças, após a filtragem das árvores, utilizando o método de morfologia matemática, com operador quadrado, e RNA com treinamento de 50% das amostras.	109
Figura 43 – Resultados dos Diferentes Algoritmos de Simulação dos Caminhos do Escoamento Superficial (a) D8; (b) Rh8; (c) MS; (d) FRh8; (e) Dinfinito; todos sobre (f) MDS filtrado, utilizando o Método de Filtragem de Morfologia Matemática, Classificação de Árvores com SVM 50%, para a Área do Centro Politécnico.	110
Figura 44 – Comparação da Influência dos Diferentes Métodos de Filtragem nos Resultados do Algoritmo de Simulação dos Caminhos do Escoamento Superficial (MS). Classificação de Árvores com SVM 50%. Área do Centro Politécnico. Métodos de Filtragem: (a) Morfologia Matemática, operador quadrado; (b) Morfologia Matemática, operador quadrado, software ALDPAT; (c) Pirâmide; (d) Declividade.	112
Figura 45 – Localização das ruas utilizadas no comparativo quantitativo dos resultados dos algoritmos de determinação da direção do fluxo de escoamento superficial.	115
Figura 46 – Comparação da Influência do Processo de Filtragem das Árvores na Simulação do Escoamento Superficial (Dinfinito). Área da Água Verde / Rebouças (a) MDS; (b) MDSu; (c) Dinfinito sobre a imagem (a); Dinfinito sobre a imagem (b). ...	116

LISTA DE TABELAS

Tabela1 – Vantagens e Desvantagens encontradas em estudos sobre RNA em Sensoriamento Remoto. Adaptado de Jarvis e Stuart (1996).	35
Tabela 2 – Softwares e etapas em que foram utilizados.	48
Tabela 3 – Quantidade de pixels amostrados, para as áreas de estudo.	65
Tabela 4 - Matriz de Confusão para o Método de Filtragem ETEW, para a Área do Centro Politécnico.....	91
Tabela 5 – Matriz de Confusão para o Método de Filtragem de Morfologia Matemática, com operador quadrado, para a Área da Água Verde / Rebouças.	91
Tabela 6 - Quantidade de pixels amostrados, com percentuais em relação à amostragem e às imagens, para as áreas de estudo.....	98
Tabela 7 – Matriz de confusão – classificador RNA, com 10% de amostra de treinamento, MDSn a partir do método de Filtragem de morfologia matemática, com operador circular, do software ALDPAT, para a área do Centro Politécnico.	99
Tabela 8 – Matriz de confusão – classificador RNA, com 50% de amostra de treinamento, MDSn a partir do método de Filtragem de morfologia matemática, com operador quadrado, para a área da Água Verde / Rebouças.....	99
Tabela 9 – Acertos Globais da RNA, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área do Centro Politécnico.	101
Tabela 10 – Acertos Globais da RNA, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área da Água Verde / Rebouças.	101
Tabela 11 – Matriz de Confusão - classificador SVM, com 40% de amostra de treinamento, MDSn a partir do método de Filtragem de morfologia matemática, com operador circular, do software ALDPAT, para a área do Centro Politécnico.	103
Tabela 12 – Matriz de Confusão - classificador SVM, com 50% de amostra de treinamento, MDSn a partir do método TIN, do software ALDPAT, para a área da Água Verde / Rebouças.	104

Tabela 13 – Acertos Globais do SVM, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área do Centro Politécnico.	105
Tabela 14 – Acertos Globais do SVM, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área da Água Verde / Rebouças.	105
Tabela 15 – Comparação entre o comprimento da rua de referencia, Rua 1, e o tamanho do fluxo gerado pelos algoritmos de determinação da direção do fluxo de escoamento superficial.	114
Tabela 16 - Comparação entre o comprimento da rua de referencia, Rua 2, e o tamanho do fluxo gerado pelos algoritmos de determinação da direção do fluxo de escoamento superficial.	114

LISTA DE SIGLAS

2D-Lea	Método de determinação da direção do escoamento proposto por Lea em 1992
ALDPAT	<i>Airborne LIDAR Data Processing and Analysis Tools</i> – Programa utilizado na comparação dos métodos de filtragem
ALS	<i>Airborne Laser Scanner</i>
D8	<i>deterministic eight neighbours</i> - Método de determinação da direção do escoamento proposto por O'Callaghan e Mark em 1984
DEMON	<i>Digital Elevation MOdel Networks</i> – método de determinação da direção do escoamento proposto por Costa-Cabral e Burges em 1994
D-Infinito	Método de determinação da direção do escoamento proposto por Tarboton em 1997
ETEW	<i>Elevation Threshold with Expand Window</i>
FRh8	Método de determinação da direção do escoamento
LADAR	<i>Laser Detection And Ranging</i>
LASER	<i>Light Amplification by Stimulated Emission of Radiance</i>
LiDAR	<i>Light Detection and Ranging</i>
MDE	Modelo Digital de Elevação
MDS	Modelo Digital de Superfície
MDSn	Modelo Digital de Superfície Normalizado
MDSu	Modelo Digital de Superfície Urbana
MDT	Modelo Digital de Terreno
MFD	Método de determinação da direção do escoamento proposto por Freeman em 1991
MS	<i>Multiple Directions based on Slope</i> – método de determinação da direção do escoamento proposto por Quinn <i>et al.</i> , 1991

Rh8	Método de determinação da direção do escoamento proposto por Fairfield e Leymarie em 1991
RNA	Redes Neurais Artificiais
SIG	Sistemas de Informação Geográfica
SRTM	<i>Shuttle Radar Topography Mission</i>
SVM	<i>Support Vector Machines</i>
TIN	<i>Triangulated Irregular Network</i>
UFPR	Universidade Federal do Paraná

SUMÁRIO

1.	Introdução	15
1.1	Objetivos.....	18
1.1.1	Objetivo Geral.....	18
1.1.2	Objetivos Específicos.....	18
1.2	Justificativa	19
2	Revisão Bibliográfica	20
2.1	<i>Laser Scanner</i>	20
2.2	Métodos de Filtragem de Dados <i>Laser Scanner</i>	23
2.3	Classificação Digital de Imagens	26
2.3.1	Redes Neurais Artificiais.....	28
2.3.2	<i>Support Vector Machine</i>	36
2.4	Modelagem dos Caminhos do Escoamento Superficial	41
3	Materiais e Métodos.....	48
3.1	Materiais	48
3.1.1	Áreas de Estudo	49
3.2	Métodos	56
3.2.1	Pré-tratamento dos dados	58
3.2.2	Métodos de Filtragem de dados <i>Laser Scanner</i>	59
3.2.3	Classificação Digital de Imagens.....	64
3.2.4	Avaliação dos Métodos de Filtragem e Classificação.....	72
3.2.5	Simulação dos Caminhos do Escoamento Superficial	72
3.2.6	Avaliação dos Resultados da Simulação do Escoamento Superficial..	78
4	Resultados e Discussões	80
4.1	Pré-tratamento dos dados.....	80
4.1.1	Centro Politécnico – UFPR	80

4.1.2	Água Verde / Rebouças	84
4.2	Métodos de Filtragem.....	89
4.3	Classificação Digital de Imagens	97
4.3.1	Redes Neurais Artificiais.....	98
4.3.2	<i>Support Vector Machine</i>	103
4.4	Filtragem de Árvores.....	108
4.5	Simulação dos Caminhos do Escoamento Superficial	110
5	Considerações Finais	118
6	Referências Bibliográficas	120
7	Apêndices	125

1. Introdução

A urbanização promovida pelo Homem, no intuito de adaptar o meio físico para seu conforto, pode produzir resultados negativos, com efeitos colaterais contra seu próprio bem estar. À medida que a ação antrópica desenha as cidades, modificam-se os sistemas de drenagem natural, intensificam-se os cenários de inundações, e, conseqüentemente, perdas materiais e problemas sociais de diversas magnitudes são gerados (LOU, 2010).

O desenvolvimento urbano produz um aumento na frequência das inundações devido à impermeabilização do solo, canalização dos cursos d'água e efeitos provocados pela formação de ilhas de calor que ocorrem em áreas densamente urbanizadas, sendo responsáveis por chuvas mais intensas e localizadas. As regiões baixas das cidades, planícies, ou os fundos de vale são identificados como locais problemáticos e com maiores índices de enchentes (SULEIMAN e BARBASSA, 2005). De acordo com Tucci e Bertoni (2003), com a impermeabilização do solo há uma sensível alteração no ciclo hidrológico natural, uma vez que a água que anteriormente infiltrava, passa a escoar, aumentando o escoamento superficial. Segundo Ellis *et al* (2009), as mudanças climáticas e a exacerbada impermeabilização dos solos são uma ameaça ao controle de águas pluviais em ambiente urbano, aumentando o risco de cheias, principalmente pela falta de capacidade de drenagem da rede pluvial. Ainda, o mesmo autor diz que uma questão importante para definir medidas para mitigação de inundações e poluição é a identificação de lugares de maior influência nesses eventos. Tais ocorrências são consequência de diversos mecanismos, em diferentes escalas espaciais, sendo destacadas as interações sub e superficial, capacidade dos sistemas de drenagem e os caminhos do escoamento.

O aumento do escoamento superficial em áreas urbanas também está associado ao problema da poluição. Neste caso, diferentes substâncias e materiais poluidores produzidos pela atividade humana são transportados pelo escoamento superficial. Por exemplo, a precipitação que incide nas coberturas de edificações lava o material nelas depositado, como poeira ou fezes de animais, também podendo transportar metais pesados e óleos produzidos pelo tráfego e depositados nas estradas.

Até recentemente, a identificação e mapeamento dos diferentes materiais presentes numa bacia hidrográfica urbana era uma tarefa árdua, se não praticamente impossível. Porém, com a disponibilização de imagens de sensoriamento remoto com alta resolução espacial, muitas restrições puderam ser superadas. Assim sendo, a classificação dos materiais que cobrem as construções ou ruas hoje é viável, o que permite estimar o grau de impermeabilização de uma região e também as potenciais fontes de poluição difusa.

Em ambientes altamente impermeabilizados, como áreas urbanas, o escoamento superficial e o transporte de sedimentos é acelerado e sua concentração depende da variação da topografia. A determinação da topografia local é uma tarefa hoje facilitada pela introdução de ferramentas, como, por exemplo, fotogrametria e sensoriamento remoto. Um dos mais recentes avanços é a tecnologia LiDAR (*Light Detection and Ranging*) também chamado de *Laser Scanning* ou *Laser Scanner*, que obtém uma alta densidade de pontos tridimensionais da superfície de uma região usando um medidor a *laser* instalado em um avião.

Devido a estes avanços, o paradigma do estudo do escoamento superficial e o transporte de sedimentos numa bacia urbana mudou e os profissionais de recursos hídricos e saneamento ambiental necessitam aproveitar as vantagens oferecidas pelas novas tecnologias e dados visando propor soluções modernas e que melhor descrevam os fenômenos naturais na superfície do terreno. Estudos como Buarque *et al* (2009), utilizam modelos de simulação dos caminhos do escoamento superficial em bacias para identificar áreas com alta concentração de escoamento superficial usando dados de altimetria obtidos por satélite. Porém, este tipo de estudo se restringe a uma escala pequena, em função da resolução dos dados orbitais.

Neste trabalho é abordado o tema da simulação dos caminhos do escoamento a partir de dados altimétricos de alta resolução espacial, focando o problema em ambientes urbanos, onde a variedade de obstáculos é maior. São utilizados dados *Laser Scanner* para a obtenção de modelos digitais da superfície da Terra como ponto de partida. Para que esta simulação do escoamento seja mais próxima da realidade, é sugerida uma metodologia para remoção de elementos que não estão presentes na superfície, ou em contato com o escoamento superficial. Para isso, é necessária a identificação dos possíveis obstáculos ao fluxo no modelo inicial, como redes de

distribuição de energia ou árvores. No caso de obstáculos como as árvores, é necessária a classificação dos pontos medidos pelo *Laser Scanner* que estão ou não no terreno, com objetivo de poder destacar os objetos acima do terreno, e poder distinguir entre gramados (onde o escoamento superficial pode existir), árvores (onde o fluxo se dá abaixo das mesmas) e de outras feições como prédios (que realmente são obstáculos e o fluxo tem que contornar). Após esta filtragem dos elementos que não estão em contato direto com o escoamento superficial, tem-se um modelo que se denominou Modelo Digital de Superfície Urbana (MDSu). Neste MDSu, tem-se apenas os elementos presentes na superfície da Terra e que se encontram em contato direto com o escoamento superficial. Além disso, também é necessário comparar o grau de eficiência dos modelos de simulação dos caminhos do escoamento superficial, identificando aqueles que melhor se adaptem a este tipo de dados.

Sendo assim, o presente documento contém uma dissertação de mestrado que aborda o tema específico do escoamento superficial em ambientes urbanos usando dados de *Laser Scanner* aerotransportado e imagens de alta resolução. Para isto, ele é organizado da seguinte maneira: neste capítulo ainda são apresentados os objetivos e a justificativa do projeto; a seguir, é apresentada uma revisão de literatura abordando os fundamentos teóricos necessários para o desenvolvimento da pesquisa; o terceiro capítulo consiste da proposta metodológica, descrevendo os métodos e passos seguidos, bem como os dados disponíveis. No quarto capítulo são apresentados e discutidos os resultados e, finalmente, no último, é feita uma avaliação final do trabalho.

1.1 Objetivos

A seguir são apresentados o objetivo geral e os objetivos específicos a serem alcançados com esta pesquisa.

1.1.1 Objetivo Geral

Estudar uma metodologia para simulação de escoamento superficial em ambientes urbanizados, utilizando dados *Laser Scanner* e imagens de alta resolução, para identificação de regiões que possam receber maior quantidade de fluxo de escoamento ou poluição.

1.1.2 Objetivos Específicos

- Comparar diferentes algoritmos de simulação e estimativa do fluxo do escoamento superficial sobre Modelos Digitais de Superfície (MDS);
- Comparar diferentes classificadores de imagens, utilizando dados de altimetria, intensidade de retorno do *laser* e informação espectral de imagens, para mapear possíveis obstáculos, como árvores;
- Comparar diferentes métodos de filtragem da nuvem de pontos *Laser Scanner*, para geração do Modelo Digital do Terreno (MDT) e Modelo Digital de Superfície Normalizado (MDSn); e
- Escolher a melhor combinação entre métodos de filtragem, classificadores e algoritmos de simulação do fluxo do escoamento superficial.

1.2 Justificativa

Os estudos de hidrologia evoluem em função das técnicas para coleta de dados e das ferramentas disponíveis. A modelagem e a compreensão do escoamento superficial vêm sofrendo o efeito dos avanços no detalhamento espacial, à exemplo da melhoria na resolução dos modelos de elevação. Se no início os estudos consideravam a bacia hidrográfica como uma unidade, com o surgimento de mapas topográficos detalhados e modelos numéricos do terreno, foi possível discretizar o espaço e considerar diferenças dentro da própria bacia. Isto, claro, aliado a ferramentas computacionais, como Sistemas de Informações Geográficas (SIG), que permitem manipular grande quantidade de dados espaciais. Nas últimas décadas foram introduzidas novas fontes de dados, alternativas ao uso de mapas, que devem ser digitalizados e muitas vezes encontram-se desatualizados. Um exemplo destas fontes de dados é a missão espacial SRTM - *Shuttle Radar Topography Mission*, que permite obter dados altimétricos de toda a superfície da Terra desde o espaço. Missões semelhantes também oferecem dados detalhados, como a *TerraSAR-X Radar Satellite Imagery*.

A descrição mais detalhada da superfície do terreno abriu novas áreas de pesquisa, como a estimativa dos caminhos que o escoamento pode seguir na bacia, a detecção de potenciais locais de alagamentos e a dispersão de poluentes. Porém, também abriu questionamentos a respeito da acurácia dos próprios modelos e métodos utilizados para a estimativa dos caminhos da água na superfície. Alguns estudos, como o de Buarque *et al* (2009), por citar um estudo no Brasil, abordam este tema utilizando dados de resolução grosseira, como as grades do SRTM, com aproximadamente 90 metros de resolução espacial. Porém não existem estudos que abordem o uso de grades altamente detalhadas, como aquelas obtidas por *Laser Scanner*, neste caso, menor que 1 metro de resolução espacial.

Desta forma, o presente trabalho se justifica, pois visa responder a estas questões, em uma escala na qual existe demanda e pouco trabalho de referência para a tomada de decisões no processo de modelagem da direção do fluxo do escoamento.

2 Revisão Bibliográfica

A seguir são apresentados os conceitos básicos e exemplos de aplicação de *Laser Scanner*, bem como, a obtenção de Modelos Digitais do Terreno a partir destes dados. Como é necessária a remoção de outros objetos situados acima do terreno, como árvores, para se obter um modelo mais fidedigno, fundamentos de métodos de classificação de imagens também são apresentados, assim como conceitos sobre algoritmos de simulação dos caminhos de escoamento superficial.

2.1 *Laser Scanner*

O sistema de varredura *laser* (*laser scanning*) aerotransportado é um método para a determinação de uma grande quantidade de coordenadas tridimensionais de pontos na superfície da Terra, com alta precisão e elevada densidade. Seu funcionamento baseia-se na emissão de um pulso de *laser* em direção da superfície. Ao atingir a superfície, parte do pulso de *laser* emitido é refletido na direção do sensor. Este mede tanto a intensidade do sinal de retorno, como também o tempo decorrido entre a emissão e a captação do retorno. Este tempo é então usado para calcular a distância sensor-objeto, considerando que o pulso *laser* se propaga à velocidade da luz (BALTSAVIAS, 1999).

O sistema é constituído de um sensor/emissor ativo, que se utiliza de um pulso de *laser*, disparado em direção aos objetos, sendo este feixe refletido pelos objetos e novamente captado pelo sistema. Ao final do levantamento é gerado como produto um arquivo com as coordenadas X, Y, Z dos pontos da superfície e também os valores da intensidade do pulso refletido pelo objeto atingido. Tipicamente, a precisão planimétrica é da ordem de 50 centímetros, enquanto a precisão altimétrica está na ordem de 10 a 15 centímetros (CENTENO e MITISHITA, 2007).

O conjunto de pontos obtidos, denominado nuvem de pontos, é denso e contém uma elevada quantidade de pontos. Este método de mapeamento é não seletivo, ou seja, os dados adquiridos formam uma nuvem de pontos que incluem superfícies como o terreno, edificações e cobertura vegetal (CHANG *et al.*, 2008).

A separação do primeiro e último retorno do *laser* permite identificar alguns pontos que penetram em algumas superfícies, por exemplo, na vegetação. Porém, em áreas urbanas, grande parte das superfícies provoca apenas um retorno, como telhados. Este conjunto de pontos pode ser tratado de duas formas: como dados vetoriais, ou em formato *raster*, sendo processado como uma grade regular. A segunda opção é geralmente mais adotada, pois implica na redução significativa da quantidade de dados.

De acordo com Zhang *et al* (2003), a tecnologia *Laser Scanner* está revolucionando a maneira de se adquirir um Modelo Digital do Terreno de alta resolução, permitindo medições rápidas e baratas sobre grandes áreas. O conjunto de dados *Laser Scanner* é caracterizado por uma alta densidade, motivo pelo qual existe pouca necessidade de interpolar valores. A interpolação pode degradar os dados, suavizando as bordas dos objetos presentes em um MDS. Porém, existem situações nas quais é necessário interpolar dados, como em regiões de “sombra” ou oclusão. Isto geralmente ocorre devido à baixa altura de voo (altura de voo de uma aeronave de, aproximadamente, 1000 metros) e a presença de objetos altos, o que é muito comum em áreas urbanas (CENTENO e MITISHITA, 2007).

A utilização de dados tridimensionais, como os obtidos por sistema *Laser Scanner*, podem também auxiliar na classificação da cobertura do solo, uma vez que a inclusão de dados de altura pode contribuir na discriminação de alguns alvos urbanos que apresentam características espectrais semelhantes (DEUS *et al.*, 2011). Centeno e Mitishita (2007) afirmam que com a inserção de dados altimétricos, é possível discriminar telhados de outros tipos de superfícies com o mesmo material, mas que estejam localizadas no chão, por exemplo.

Recentemente, a extração automática de objeto de dados *Laser Scanner* tem atraído grande atenção. O nível de detalhes e a qualidade da nuvem de pontos coletada motivou a comunidade científica a investigar a possibilidade de extração automática de objetos destes dados (CHANG *et al.*, 2008). De fato, estes sistemas permitem a coleta de grandes volumes de dados com elevada acurácia planialtimétrica. Consequentemente, surgiram muitas aplicações envolvendo reconstrução de superfícies e extração de feições. Tais aplicações implicam na solução de problemas específicos envolvendo segmentação, classificação e filtragem de objetos para a geração de Modelos Digitais do Terreno (MDT) e de Superfície (MDS). Também têm sido bastante

difundidas as aplicações que combinam dados de varredura *laser* com dados de outros sensores (imagens aéreas e de satélite) para possibilitar a extração semiautomática, ou mesmo automática, de forma acurada e confiável, de objetos, como: edifícios, malha viária, vegetação, etc. (FAZAN e POZ, 2011).

Evans (2008) apud Ellis *et al* (2009) relata que a detecção de feições que possam causar barreiras ao fluxo do escoamento superficial, obtidos a partir de dados *Laser Scanner*, pode proporcionar um mapeamento do fluxo muito mais eficaz. Ellis *et al* (2009) complementam dizendo que a resolução dos Modelos Digitais de Terreno (MDT), ou Elevação (MDE), é que determina a escala para a modelagem a ser realizada. Isto porque é a precisão do MDE, utilizada nos algoritmos de modelagem, que pode influenciar no caminho do escoamento superficial, podendo, ou não, representar feições como paredes, cercas, becos, calçadas, pontes, viadutos, etc. Tais elementos podem ser determinantes na modelagem do fluxo, uma vez que estes podem causar atalhos ou obstáculos a este escoamento dentro do modelo. Atualmente, com a utilização de Sistemas de Informação Geográfica (SIG), pode-se gerenciar grandes quantidades de dados e, com MDT (ou MDE) de alta resolução, obtidos por *Laser Scanner* ou por fotogrametria, pode-se obter uma ferramenta muito poderosa para a gestão urbana detalhada.

Muitos estudos ambientais e projetos de engenharias utilizam-se do mapeamento do fluxo de água, sedimentos, nutrientes ou outros materiais através de determinada área de interesse. Na modelagem da qualidade da água, por exemplo, as previsões de cargas de nutrientes dependem da precisão do mapeamento dos fluxos em ambiente terrestre, determinando detalhes do transporte de poluentes. Especialistas de qualidade da água são desafiados a aumentar o controle sobre o escoamento superficial que contenham poluentes, originados de maneira difusa. Sendo assim, é necessária a identificação precisa do escoamento superficial para, em seguida, se determinar práticas de controle do escoamento (ENDRENY e WOOD, 2003). Tarboton (1997) diz que a determinação das direções do escoamento, ou do fluxo, com base em modelos digitais de elevação, são necessárias em hidrologia para determinar os caminhos de água, sedimentos e movimento de contaminantes. Além disso, a identificação das vias de drenagem e escoamento com base em MDE, juntamente com modelos hidrológicos (por exemplo, Beven *et al.* 1994, Lee e Chu, 1996, citados em WILSON *et al.*, 2008), fornecem meios para parametrizar modelos físicos, espacialmente distribuídos, onde são capazes de

representar e incorporar a heterogeneidade espacial. Segundo Erskine *et al* (2006), a área contribuinte, estimada a partir de modelos digitais de elevação é fundamental para uma ampla gama de modelos hidrológicos distribuídos. Este atributo, também chamado de área de aclave, área de contribuição, e acumulação de fluxo, representa a área que pode produzir escoamento para determinado local de interesse.

De acordo com Coelho *et al* (2002), em várias aplicações de engenharia é conveniente que esteja disponível diretamente o MDS, como no planejamento urbano, detecção de construções irregulares ou projetos de rede de telefonia celular. Porém quando se trata de temas como planejamento de sistema viário, projetos de hidrologia, simulação de escoamento de fluidos (enchentes, espalhamento de manchas de óleo) é necessário existir um Modelo Digital de Terreno (MDT).

Entretanto, segundo Centeno e Mitishita (2007), o problema central, na produção de Modelos Digitais do Terreno em áreas urbanas, consiste em separar os pontos correspondentes ao terreno daqueles originados em outras superfícies, como construções ou árvores.

2.2 Métodos de Filtragem de Dados *Laser Scanner*

Vale novamente destacar que o conjunto de dados obtidos pela varredura a *laser* não correspondem apenas ao terreno, mas também a outros objetos, como árvores ou construções. Quando os dados se referem a pontos do terreno, é possível construir um Modelo Digital do Terreno (MDT). Já quando o modelo inclui, além do terreno, os objetos a ele superpostos, fala-se em Modelo Digital da Superfície (MDS).

De acordo com Weidner e Föerstner (1995), após a interpolação das grades do MDT e do MDS, uma terceira grade pode ser derivada calculando a diferença entre o MDS e o MDT. Trata-se, neste caso, de uma grade que contém apenas os objetos acima do terreno, sendo conhecida como Modelo Digital de Superfície Normalizado, ou MDSn. Neste modelo, apenas a altura dos objetos acima do terreno é representada, o que simplifica a análise. Em regiões de relevo acidentado, pontos do terreno e pontos no telhado de um prédio podem ter a mesma coordenada altimétrica na grade. Após a normalização, o efeito do terreno é eliminado. A vantagem do uso do modelo

normalizado no estudo de áreas urbanas é que o mesmo permite obter diretamente a altura das construções. A Figura 1 traz uma representação deste problema.




Figura 1 – (a) Representação de um caso de terreno acidentado, (b) e a mesma situação após normalização.

A Figura 1a demonstra a representação de uma situação em que elementos que não são do terreno, como árvores, casas ou prédios, podem possuir uma cota menor que a cota do terreno na vizinhança, ou mesmo que prédios possam ter cota menor que casas, ou vegetação rasteira com cota maior que árvores. Já a Figura 1b apresenta a mesma situação após a operação de normalização, onde os efeitos do relevo são removidos, e todas as cotas das feições são maiores que o terreno, ajustando também a condição de que o prédio tem cota maior que a casa, assim como árvores com cotas maiores que vegetação rasteira, como gramados.

Para Chang *et al* (2008), os métodos de remoção dos pontos que não são do terreno, também conhecidos como métodos de filtragem, têm sido o foco de muitos pesquisadores. Este autor cita que existem muitas aplicações, como, por exemplo, a geração de linhas de contorno de mapas topográficos, projetos de construção de estradas, delimitação de zonas de inundação, entre outros.

Segundo Zhang *et al.* (2003) e Centeno, Kishi e Mitishita (2009), para gerar um MDT, o terreno tem que ser identificado e os pontos que não são do terreno devem ser retirados, sendo esta filtragem considerada como desafiadora por muitos autores. Na literatura encontram-se descritas diferentes alternativas para a solução deste problema. A maior parte desses métodos se baseia na identificação de pontos do terreno em função da declividade local, continuidade da superfície ou da distância do ponto a um plano de referência que corresponderia ao terreno.

Coelho *et al* (2002) afirma que métodos e parâmetros são ainda exaustivamente investigados por autores em vários países, de forma que os MDT possam ser extraídos de forma eficiente, eliminando os objetos indesejados e, simultaneamente, preservando a configuração natural do terreno.

Ainda, para Coelho *et al* (2002), os métodos de extração de MDT podem seguir vários princípios. Como exemplos, o mesmo autor diz que podem ser citados o método do bloco mínimo, onde é atribuído para todos os elementos de uma matriz-filtro com 5x5 até 15x15 pixels o menor valor de altura entre eles; o método das envoltórias côncavo-convexas, onde linha por linha da imagem são analisadas por um procedimento geométrico; o operador de erosão usado em morfologia matemática; tratamentos estatísticos por mínimos quadrados utilizando funções de pesos; processamento com auxílio de programas de classificação de feições em imagens; e até mesmo métodos mais sofisticados utilizando elementos finitos, que incluem controle de curvatura e de torção da superfície do terreno.

Basicamente, existem dois erros em quaisquer métodos de filtragem. O primeiro é o erro de comissão, que classifica os pontos que não são do terreno como terreno, mantendo tais pontos. O outro é o erro de omissão, que remove pontos do terreno por engano. A etapa crítica do processo de filtragem consiste em se determinar um limite ideal para que os erros de omissão e comissão possam ser minimizados (ZHANG *et al.*, 2003).

Kraus *et al* (1997) apud Zhang *et al* (2003), utilizaram iterativamente interpolação dos mínimos quadrados para remover árvores em áreas de floresta e obter o MDT. Este método foi depois estendido para área urbanas para filtragem de edifícios por Pfeifer *et al.* (2001) apud Zhang *et al* (2003). Entretanto, foi concluído que este método não traz bons resultados para áreas densamente urbanizadas.

Zhang *et al* (2003) também diz que Vosselman (2004) propôs um filtro baseado na inclinação entre os pontos do *Laser Scanner* e seus vizinhos. Os pontos são classificados como terreno quando atendem certo limiar predefinido. Quanto menor for este valor de limiar, maior quantidade de pontos será removida. Um limiar razoável pode ser atribuído por tentativas ou quando se tem conhecimento prévio da área de estudo. A determinação deste limiar acaba por se tornar uma análise subjetiva.

Zhang *et al* (2003) afirma que Kilian *et al* (1996) propôs um método para remover os pontos que não fossem pertencentes ao terreno usando filtro morfológico. Em seu método, um ponto com a mais baixa elevação dentro de um dado tamanho de janela é detectado e então é aplicado o operador de abertura sobre um conjunto de dados. Todos os pontos do terreno são identificados movendo-se a janela e o operador morfológico.

E, finalmente, em seu estudo, Zhang *et al* (2003) concluí que os filtros morfológicos podem remover elementos acima o terreno. No entanto, é difícil que todos os objetos, de diversos tamanhos, sejam filtrados utilizando um tamanho de janela fixa. Este problema pode ser resolvido aumentando o tamanho da janela de filtragem gradualmente. Os resultados experimentais mostraram que a proposta do filtro morfológico progressivo, com incremento do tamanho da janela, geraram bons resultados na filtragem tanto em ambientes urbanos como em regiões montanhosas.

2.3 Classificação Digital de Imagens

Após a separação dos objetos que estão acima do terreno, é necessária a identificação da natureza destes objetos, para determinar os casos em que realmente são ou não obstáculos ao fluxo do escoamento superficial. Tradicionalmente, a detecção de diferentes usos e ocupação do solo em dados de sensoriamento remoto é realizada por meio de um intérprete, sendo um processo que demanda grande custo operacional. Por esse motivo, um processo automático reduziria a demanda de trabalho manual necessário para o desenvolvimento da tarefa, aumentando a agilidade e a confiabilidade no processo (DEUS *et al.*, 2011).

A classificação digital de imagens de sensoriamento remoto tem ganhado, nas últimas décadas, reconhecimento como técnica para suprir a escassez dos mapeamentos temáticos. A extração automatizada de informações demanda métodos que consigam reproduzir a capacidade humana de interpretar uma imagem. Neste contexto, ganha significado a integração de novos métodos de análise como, por exemplo, o uso de técnicas de inteligência artificial, como as Redes Neurais Artificiais (RNA), para representar o conhecimento do analista humano para efetuar a interpretação e classificação de imagens (ARAKI, 2005).

Segundo Centeno (2009), uma maneira de tornar a interpretação de imagens mais simples consiste em separar grupos de pixels com características espectrais similares. Partindo da hipótese de que pixels cobrindo um mesmo alvo devem ter características espectrais similares, algoritmos computacionais podem ser usados para dividir os pixels de uma imagem em grupos, segundos suas leituras em cada banda espectral. Este processo é denominado classificação digital de imagens e consiste em, a partir dos valores do contador digital de uma imagem, gerar uma nova imagem, mais simples, onde cada pixel está associado a uma categoria, ou classe.

A classificação digital de imagens utiliza a informação armazenada nos contadores digitais (de cada pixel, por exemplo), de uma ou mais bandas espectrais, classificando-o em cada classe, sendo considerada assim um reconhecimento de padrão espectral (KAVZOGLU e COLKESEN, 2009). Recentemente, a aplicação do conceito "orientado a objeto" tem surgido como novo paradigma na classificação. Porém, neste estudo a classificação se restringe ao pixel, por considerar que esta unidade é mais eficiente no processo de integração da imagem com os dados do *Laser Scanner*, uma vez que esses dados podem ser organizados em formato *raster*, ou seja, matriz ou imagem, compatível com a resolução da imagem. Desta forma, seria atribuído a cada pixel da imagem mais informação, como uma nova camada ou banda espectral, para auxiliar na classificação.

Os classificadores podem ser enquadrados em dois grupos: os não supervisionados e os supervisionados. Dentre os não supervisionados estão, o IsoData e o K-médias; dentre os supervisionados estão, o paralelepípedo, o mínima distância, máxima verossimilhança, mapeamento por ângulo espectral, árvores de decisão, Redes Neurais Artificiais e, mais recentemente, o *Support Vector Machines* (SVM, Máquinas de Vetor de Suporte – termo pouco utilizado em português).

Classificadores supervisionados também são comumente divididos em paramétricos e não paramétricos. Classificadores paramétricos (por exemplo, a máxima verossimilhança) exigem conhecimento prévio/suposições sobre a distribuição estatística dos dados a serem classificados, o que é, muitas vezes, difícil de atingir na prática (PETROPOULOS, ARVANITIS e SIGRIMIS, 2012).

Recentemente, muitos estudos têm mostrado que as técnicas como Redes Neurais Artificiais, árvores de decisão e *Support Vector Machines* podem ser capazes de

classificar um conjunto de dados com maior precisão do que os convencionais classificadores estatísticos (FOODY e MATHUR, 2004b).

A utilização de Redes Neurais Artificiais (RNA) emerge como uma alternativa vantajosa até mesmo aos classificadores de imagens baseados em conceitos estatísticos, como o da Máxima Verossimilhança. Isto porque nenhuma hipótese prévia sobre a distribuição dos dados a serem classificados é exigida e os dados de entrada podem ter escalas diferentes. Sua capacidade de distribuição dos dados de entrada é mais sutil do que os métodos estatísticos tradicionais e a capacidade de formar fronteiras de decisão não-lineares no espaço de características têm aumentado o seu uso (BOTELHO, 2004).

2.3.1 Redes Neurais Artificiais

Desde a década de 1990, as Redes Neurais Artificiais (RNA) têm sido cada vez mais utilizadas como alternativa aos classificadores clássicos (EGMONT-PETERSEN, RIDDER e HANDELS, 2002).

De acordo com Heermann e Khazenie (1992), as Redes Neurais Artificiais têm sido estudadas por cientistas de diversas áreas, incluindo ciência da computação, psicologia, biologia e química orgânica. Embora existam várias motivações para o estudo, a ideia principal está no cálculo inspirado no sistema biológico. Lek e Guégan, (1999) afirmam que muitos estudos têm desenvolvido vários tipos de RNA para resolver diferentes problemas, como generalização, otimização, mineralização de dados, controle e predição de vários cenários, etc. Redes Neurais Artificiais têm se tornado o foco de muita atenção, principalmente por causa de sua ampla aplicabilidade e, principalmente, por tratar de casos considerados complicados. RNA podem identificar e aprender padrões relacionando conjunto de dados de entrada e valores de saída correspondentes. Após o treinamento, RNA podem ser usadas para prever o resultado relacionado a um novo grupo de dados de entrada. Elas podem resolver problemas com dados não lineares e muito complexos, mesmo sendo dados imprecisos e ruidosos.

Segundo Petropoulos, Arvanitis e Sigrimis (2012), Haykin (1994) descreveu RNA como um processador maciçamente paralelo, constituído por unidades de processamento simples, que tem uma tendência natural para armazenar conhecimento empírico e torná-lo disponível para o uso.

RNA são estruturas de mapeamento não lineares, com base no funcionamento do cérebro humano. Têm se mostrado como bons aproximadores de funções para qualquer tipo de dados. São poderosas ferramentas para modelagem, especialmente quando são desconhecidas as relações entre os dados (LEK e GUÉGAN, 1999).

Resumidamente, uma RNA compreende um grande número de unidades de processamento simples, os neurônios ou nós, organizados em camadas, conectados por ligações ponderadas de acordo com uma arquitetura especificada.

Usualmente, as camadas são classificadas em três grupos:

- Camada de Entrada: onde os padrões são apresentados à rede;
- Camadas Ocultas (Intermediárias ou Escondidas): onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características;
- Camada de Saída: onde o resultado final é concluído e apresentado.

Quando as informações são transmitidas em apenas uma direção através da rede, sendo alimentada por um lado e movendo através das sucessivas camadas, esta topologia é conhecida como uma rede *feedforward* (HEERMANN e KHAZENIE, 1992). Conforme Lek e Guégan (1999), a arquitetura de uma rede neural *feedforward* é em camadas, onde os elementos não-lineares (neurônios) estão dispostos em camadas sucessivas, e os fluxos de informação são unidirecionais, a partir da camada de entrada para a camada de saída, passando pelas camadas escondidas ou ocultas. Cada camada é constituída por unidades de processamento não-lineares chamadas de neurônios, que possuem ligações ponderadas entre neurônios de camadas sucessivas.

A Figura 2 apresenta uma representação de RNA, com os neurônios dispostos nas camadas de entrada, camada oculta e camada de saída. O número de neurônios em cada camada pode ser variável, assim como o número de camadas ocultas.




Figura 2 – Representação gráfica de uma Rede Neural Artificial.

Em aplicações de sensoriamento remoto, por exemplo, para a classificação de imagens, Petropoulos, Arvanitis e Sigrimis (2012) afirmam que os nós na camada de entrada poderiam ser as bandas espectrais de uma imagem, as características de textura ou outras informações obtidas por sensoriamento remoto. Cada um dos nós de saída representa cada classe. As camadas escondidas são constituídas por vários nós. As ligações ponderadas entre os nós carregam o fluxo de informação através da rede. A aprendizagem ocorre através do ajuste dos pesos das ligações para minimizar a diferença entre o resultado proposto pela rede e o fornecido pelo usuário, ou seja, a classificação correta dos pixels da imagem.

A topologia da rede, ou seja, o número de camadas, o número de neurônios nas camadas, pesos iniciais das ligações entre as camadas e taxa de aprendizado são fatores que influenciam o desempenho deste classificador (PAL e MATHER, 2004).

A implementação de RNA requer a atribuição de alguns parâmetros, os quais incluem a taxa de aprendizado, momento de treinamento (podendo ser entendido como a tendência de continuar o aprendizado e não ficar aprisionada em um mínimo local), critério de fim de treinamento e número de camadas ocultas. Além disso, deve-se determinar as funções de ativação dos neurônios (PETROPOULOS, ARVANITIS e SIGRIMIS, 2012).

Segundo Egmont-Petersen, Ridder e Handels (2002), vários resultados teóricos sobre as capacidades de aproximação de RNA foram comprovadas. Embora RNA *feedforward* de duas camadas possam aproximar qualquer função (mesmo descontínua) com uma determinada precisão, os resultados teóricos sobre acurácia dos resultados é escassa.

De acordo com Heermann e Khazenie (1992), se poucos neurônios são colocados na camada oculta, a rede pode não conter um grau de liberdade necessário na análise. Porém, a desvantagem de um grande número de nós é o desempenho computacional e a perda de capacidade de generalização da rede, ou seja, a rede pode “decorar” os dados de treinamento, e não conseguir ter boa resposta para novos dados a serem classificados. Portanto, o equilíbrio deve ser desenhado.

Em Petropoulos, Arvanitis e Sigrimis (2012) é descrito que a taxa de aprendizado representa com que magnitude os pesos das conexões serão alterados. Valores elevados desta taxa podem diminuir o tempo de treinamento, mas podem aumentar o risco de oscilações ou divergência nos resultados. Jarvis e Stuart (1996) dizem que o parâmetro momento de treinamento não foi considerado muito útil em estudos anteriores em sensoriamento remoto, entretanto, em seus estudos, sugerem que este seja usado para suportar uma maior taxa de aprendizagem.

Vieira (2000) apud Botelho (2004) reporta que o algoritmo de aprendizado da rede neural mais utilizado na classificação de imagem oriundas do sensoriamento remoto é o *backpropagation* (retropropagação, termo pouco utilizado em português).

Segundo Lek e Guégan (1999), a base conceitual do algoritmo *backpropagation* foi apresentado pela primeira vez em Webos (1974), em seguida, independentemente reinventada por Parker (1982), e apresentado a um público por Rumelhart *et al* (1986).

Backpropagation é um algoritmo de gradiente descendente, que minimiza o erro entre a saída obtida pela rede e os resultados fornecidos para o treinamento. Portanto, para esta etapa, um conjunto de pares de dados de entrada e saída é apresentado repetidamente à rede. Para diminuição do erro entre o resultado da rede e o esperado, os pesos vão sendo ajustados conforme a taxa de aprendizado (PAL e MATHER, 2004).

O algoritmo *backpropagation* é o foco de grande parte da pesquisa em redes neurais (CHETTRI, CROMP e BIRMINGHAM, 1992). Segundo Lek e Guégan (1999), o *backpropagation* é um dos algoritmos de treinamento de redes mais fáceis. Sua

aprendizagem e procedimento de atualização são baseados em um conceito relativamente simples: se a rede dá a resposta errada, então os pesos são corrigidos.

Uma rede *backpropagation* é treinada por apresentação de exemplos. Um conjunto representativo de entrada e padrões de saída é selecionado. À medida que cada padrão de entrada é apresentado, as ligações de rede são ajustadas de modo que os resultados sejam o mais próximo do resultado desejado. Todos os padrões são repetidamente apresentados à rede até que esta "aprenda" os padrões (HEERMANN e KHAZENIE, 1992).

Heermann e Khazenie (1992) afirmam que a técnica de rede neural de *backpropagation* parece ser viável para a classificação de imagens de satélite. O algoritmo *backpropagation* reduz a principal desvantagem das redes neurais, que é o tempo de treinamento. O mesmo autor ainda acrescenta que uma rede *backpropagation* é facilmente modificada para acomodar mais canais ou para incluir informação espacial e temporal. A camada de entrada pode simplesmente ser aumentada para aceitar os dados adicionais.

Tipicamente, para uma RNA ser aplicada, é necessário tanto um conjunto de treinamento como de teste. Ambos os conjuntos de treinamento e teste contêm pares com informações de entrada e suas respectivas saídas, tomadas a partir de dados reais. A primeira é usada para treinar a rede, e a segunda para avaliar o desempenho da rede. Na fase de teste, os dados de entrada alimentam a rede e os padrões de saída desejados são comparados com os obtidos através da rede neural. A concordância, ou não, destes dois conjuntos dá uma indicação do desempenho da rede neural (LEK e GUÉGAN, 1999).

Uma vez que o treinamento e validação da rede são realizados, ela é alimentada *feedforward* (alimentada para frente, em uma direção) para produzir a classificação. A imagem inteira a ser classificada é apresentada à rede, pixel a pixel, onde cada pixel será atribuído a uma classe (PAOLA e SCHOWENGERDT, 1995).

Feedforward backpropagation são redes menores e levam menos tempo para treinamento, exigem menos dados para treinamento e têm a vantagem que podem ser adaptadas individualmente para discriminar certas características (JARVIS e STUART, 1996).

Jarvis e Stuart (1996) citam que vários estudos também comparam as classificações por redes neurais com técnicas paramétricas mais tradicionais, e alguns

destes resultados têm relatado classificações significativamente melhores com as redes neurais, e têm sido motivo de entusiasmo, ou outros que concluíram em favor de redes, embora com otimismo mais cauteloso.

Ainda, Paola e Schowengerdt (1995) afirmam que outros estudos examinaram o classificador RNA com mais detalhes e comparando-a com classificadores padrões, como o máxima verossimilhança. Alguns pesquisadores encontraram os classificadores estatísticos superiores, enquanto a maioria encontrou que RNA são semelhantes ou superiores.

Chettri, Crompton e Birmingham (1992) comparam as redes neurais de *backpropagation* com um classificador de máxima verossimilhança. Alguns dos itens avaliados foram: o tempo de treinamento, exatidão, tempo e sensibilidade da classificação. O nível de exatidão obtido, ou seja, o número de dados classificados corretamente em um conjunto de teste, foram melhores quando obtidos pela RNA do que quando obtidos pelo classificador máxima verossimilhança. Os requisitos de memória e tempo de classificação foram equivalentes para ambos os métodos. Já para o tempo de treinamento, para o classificador máxima verossimilhança foi menor. Foi concluído que as redes neurais são um candidato melhor como método para classificação supervisionada de dados de sensoriamento remoto.

Porém, Jarvis e Stuart (1996) encontraram em seus resultados que a acurácia das RNA foi 7% menor que a acurácia do classificador máxima verossimilhança. Este autor concluiu em seu estudo que, com as circunstâncias apresentadas, um classificador paramétrico tradicional como a máxima verossimilhança teria sido o mais eficiente. No entanto, em outras situações, quando os dados não atendem as exigências mais rigorosas de um classificador paramétrico, um classificador como RNA pode ser preferido.

Paola e Schowengerdt (1995) também comparou RNA e o classificador máxima verossimilhança. O algoritmo máxima verossimilhança foi escolhido para esta comparação por ser amplamente utilizado como classificador padrão. Uma das principais diferenças entre os algoritmos é a velocidade, sendo o treinamento da RNA mais lento. Entretanto, o tempo de classificação, depois da rede treinada, foi considerado menor para a RNA. Chegou-se a conclusão de que a rede neural, por ser não paramétrica, é mais robusta para seleção, definição e treinamento das classes,

mesmo com um número menor de pixels para treinamento, enquanto que o algoritmo de máxima verossimilhança é mais sensível a pureza das classes.

Paola e Schowengerdt (1995) diz que tanto em seu trabalho, como em de outros, as redes neurais mostraram-se uma ferramenta útil para sensoriamento remoto e classificação de imagens. A maior desvantagem do método é o tempo de treinamento. Como os computadores se tornam cada vez mais poderosos, a velocidade de processamento aumenta e as redes neurais se tornam mais atraentes. Este aumento de velocidade, juntamente com a capacidade flexível da rede neural e habilidade de usar conjuntos de treinamento pequenos, fazem da rede neural uma ferramenta em potencial para classificação de imagens multiespectrais de sensoriamento remoto. Paola e Schowengerdt (1995) ressalta que o mesmo conjunto de dados de treinamento foram utilizados, tanto pela máxima verossimilhança como pelas redes neurais. Um estudo similar é apresentado em Chettri, Cromp e Birmingham (1992).

A Tabela1 resume algumas vantagens e desvantagens encontradas em estudos sobre RNA em Sensoriamento Remoto por Jarvis e Stuart (1996).

Tabela1 – Vantagens e Desvantagens encontradas em estudos sobre RNA em Sensoriamento Remoto. Adaptado de Jarvis e Stuart (1996).

Vantagens	Desvantagens
Adaptação a componentes não lineares (Wang, 1993)	Tempo de treinamento lento para grandes redes em máquinas sequenciais (Kanellopoulos <i>et al.</i> , 1992)
Relativa tolerância a dados inconsistentes e com ruídos (Foody, McCulloch, e Yates, 1992)	Problemas com padrões previamente não especificados ou amostras não representativas em casos de treinamentos supervisionados
Capacidade de alocação e dados contínuos e nominais (Benediktsson, Swain e Ersoy, 1990)	Potencialmente grandes requisitos de memória para alguns tipos de redes (Bischof, Schneider, e Pinz, 1992)
Algoritmo de aprendizagem não programado a priori para a rede (Sui, 1992)	Arquiteturas e algoritmos de treinamento ainda permanecem como problemas a serem pesquisados (Hepner e outros, 1990)
Não necessita de suposições estatísticas sobre a distribuição dos dados de entrada (Foody, McCulloch, e Yates, 1992)	Problemas com mínimos locais (Benediktsson, Swain e Ersoy, 1990)
Paralelização potencial de algoritmos (Lee e outros, 1990)	Dificuldades na explicação do modelo e processo (Bischof, Schneider, e Pinz, 1992)
Uma vez treinada, são computacionalmente eficientes (Lee e outros, 1990)	Disponível em apenas alguns dos principais softwares de processamento de imagem
Capacidade de usar conjuntos de treinamento menores do que os classificadores tradicionais (Hepner e outros, 1990)	Dependem da especificação de dados de entrada relevantes
Capacidade de se adaptar a alterações nos dados ao longo do tempo (Lewis e outros, 1992)	
Incorporação indutiva de textura (Bischof, Schneider, e Pinz, 1992; Fitzgerald e Lees, 1994)	
Capacidade de incorporar dados contextuais (Benediktsson, Swain e Ersoy, 1990)	
Saída reflete possibilidades fuzzy (Campbell e Hashim, 1992; Civco, 1993)	

2.3.2 Support Vector Machine

Conforme Burges (1998), *Support Vector Machines* (SVM) é uma ferramenta que fornece uma nova abordagem para o problema de reconhecimento de padrões. SVM é um classificador supervisionado que tem por objetivo encontrar um hiperplano que separa um conjunto de dados em classes discretas, utilizando-se de processo iterativo e de exemplos de treinamento para ajustar este hiperplano. Para isto, SVM encontra um hiperplano que otimiza a separação das classes, também conhecido como hiperplano ótimo ou ideal, que maximiza a distância entre as classes, sendo usado como fronteira de decisão (MOUNTRAKIS, IM e OGOLE, 2011; KAVZOGLU e COLKESEN, 2009; PETROPOULOS, ARVANITIS e SIGRIMIS, 2012; COSTA, ZEILHOFER e RODRIGUES, 2010; ANDREOLA e HAERTEL 2009).

Foody e Mathur (2004) afirma que muitos hiperplanos podem ser ajustados para separar as classes, mas existe apenas um hiperplano ótimo de separação, o qual é ajustado entre as classes, localizado de tal forma que a distância do mesmo às classes seja a maior possível.

Como se pode perceber na Figura 3a, existem vários hiperplanos separando as duas classes. No entanto, existe apenas um plano hiperplano que proporciona uma margem máxima entre as duas classes, chamado de hiperplano ótimo, Figura 3b (KAVZOGLU e COLKESEN, 2009). Os pontos que limitam a margem são chamados vetores de suporte, também estão representados na Figura 3b.

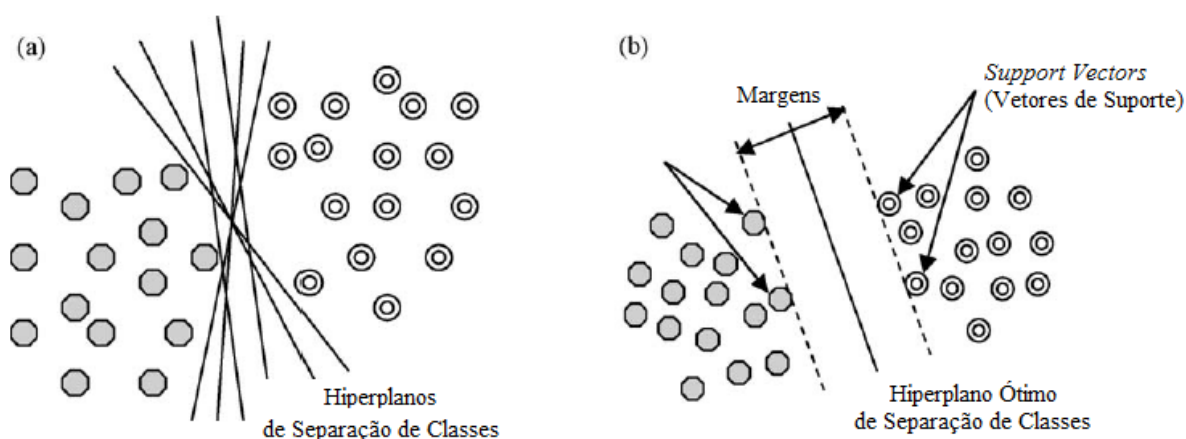


Figura 3 - (a)Vários hiperplanos que podem separar as classes, (b) hiperplano ótimo (KAVZOGLU e COLKESEN, 2009).

Conforme Foody e Mathur (2004), SVM são muito atraentes para a classificação de dados de sensoriamento remoto. Esta abordagem busca encontrar o hiperplano ótimo de separação entre as classes, utilizando os dados do treinamento que se encontram na fronteira da classe, conhecidos como os vetores de suporte (*support vector*), e os outros dados podem ser descartados. Assim, é esperado que esta abordagem produza ótimos resultados, com conjuntos de treino pequenos, o que pode ser uma característica muito vantajosa. A base da abordagem do SVM é de que apenas as amostras que se encontram nas fronteiras das classes é que são necessárias para a discriminação.

Em essência, de acordo com Foody e Mathur (2004 b), a classificação com SVM é baseada na noção de que se formar um hiperplano ótimo de separação entre classes, concentrando-se nas amostras de treino que se encontram na extremidade das distribuições de classe, os vetores suporte. Isto também é relatado em Ogole (2011) e Ales (2008), que declaram que o subconjunto de pontos que ficam na margem (vetores de suporte) são os únicos que definem o hiperplano de margem máxima.

Com isso, pode-se dizer que o processo baseia-se na noção de que apenas as amostras de treino que se encontram nas fronteiras entre as classes são necessárias para a discriminação. Por conseguinte, apenas uma pequena quantidade das amostras de formação normalmente adquiridas, são realmente utilizados na montagem dos hiperplanos (BROWN, GUNN e LEWIS, 1999). Sendo assim, seus ganhos de desempenho parecem ser bem adequados para aplicações de sensoriamento remoto, onde uma quantidade limitada de dados de referência é necessária (MOUNTRAKIS, IM e OGOLE, 2011).

Andreola e Haertel (2009) afirmam que a abordagem utilizada pelo método SVM apresenta um grande potencial para classificação destes dados nas condições frequentemente encontradas na prática, quando se dispõe de um número limitado de amostras de treinamento, geralmente insuficiente para uma estimativa confiável dos parâmetros em abordagens de classificadores paramétricos.

A principal conclusão disto é que uma descrição completa de cada classe não é necessária para uma classificação precisa, apenas as amostras de treinamento localizadas nos limites de cada classe contribuem para a análise. A aquisição de amostras de treinamento além da região de fronteira é, portanto, um esforço desnecessário e um desperdício (FOODY e MATHUR, 2004b). Porém, Kavzoglu e

Colkesen (2009) alertam que a seleção de pixels adequados depende da familiaridade do analista com a área geográfica e o seu conhecimento dos tipos reais de cobertura da superfície presentes na imagem.

Ou seja, como dito por Mountrakis, Im e Ogole (2011), a característica mais importante do SVM é a capacidade de classificação de dados a partir de uma quantidade limitada dos dados de treino. Comparado com métodos alternativos, tais como redes neurais *backpropagation*, SVM pode ter uma precisão comparável com um tamanho de amostra muito menor.

Uma das principais diferenças entre o RNA e SVM é que, enquanto que para a RNA pode haver muitas soluções, o SVM converge para uma única solução ótima. Esta é uma "vantagem" prática do SVM, quando comparado com RNA (EVGENIOU e PONTIL, 2001). Ou seja, como afirmado em Burges (1998), SVM diferem radicalmente das abordagens comparáveis, como redes neurais, pois sempre encontram um mínimo global, uma solução ótima.

Além disso, sendo não-paramétrico, SVM não assume uma distribuição estatística conhecida a priori dos dados a serem classificados. Isto é particularmente útil, porque os dados adquiridos a partir de imagens de sensores remotos geralmente têm distribuições desconhecidas. Isso permite que os SVM superem técnicas com base na classificação de máxima verossimilhança, pois a normalidade nem sempre dá uma suposição correta da distribuição real dos pixels em cada classe (Su *et al.*, 2009 apud MOUNTRAKIS, IM e OGOLE, 2011).

Entretanto, Andreola e Haertel (2009) e Mountrakis, Im e Ogole (2011) alertam que, na sua forma mais simples, SVM são classificadores binários que atribuem uma dada amostra a uma classe, de apenas duas classes possíveis. No entanto, dados de sensoriamento remoto de cenas naturais envolvem a presença de um número maior de classes. Desta forma, aplicações de técnicas SVM na classificação de imagens de sensoriamento remoto requerem abordagens especiais.

Duas abordagens principais têm sido sugeridas para a aplicação de SVM na classificação multiclases. Em cada uma, a base tem sido a de reduzir o problema multiclasse a um conjunto de problemas de binário, permitindo a utilização da abordagem básica do SVM (FOODY e MATHUR, 2004).

Segundo Petropoulos, Arvanitis e Sigrimis (2012), SVM pode ser estendido a mais do que duas classes, dividindo o problema em uma série de separações binárias. Isto pode ser feito escolhendo-se entre duas abordagens: um contra todos e um contra um.

Diversos métodos são conhecidos para ajustar SVM em um cenário multiclasse, incluindo: (a) a formação de um classificador para distinguir cada classe de todas as outras classes, comumente chamado de "um contra todos", (b) a formação de um classificador para distinguir entre cada par de classes, chamado de "um contra um" (LODHA *et al.*, 2006).

De acordo com Vapnik *et al* (1995) apud Pal e Mather (2004), “um contra todos” compara uma determinada classe com todos os outros conjuntos, gerando tantos classificadores quanto classes existirem. Já para Knerr *et al.*(1989) apud Pal e Mather (2004), o “um contra um” aplica-se a comparações entre pares de classes. Todas as possíveis combinações de duas classes são avaliadas a partir do conjunto de treinamento de n classes, havendo um total de $n*(n-1)/2$ classificadores. A aplicação de cada classificador criado para os vetores de dados dá um voto para a classe vencedora na análise. O pixel será então atribuído à classe com maior número de votos recebidos.

A fim de representar formas mais complexas do que hiperplanos lineares, o classificador pode utilizar funções Kernel, sendo as mais utilizadas as de base polinomial, radial (RBF) e Kernel sigmóide (PETROPOULOS, ARVANITIS e SIGRIMIS, 2012).

Embora seja relatado que SVM produzam resultados da classificação mais precisos do que os métodos convencionais, a seleção de função Kernel ideal e seus parâmetros são as principais questões que afetam em grande parte as suas performances (KAVZOGLU e COLKESEN, 2009).

Ainda, Mountrakis, Im e Ogole (2011) afirma que algumas das funções Kernel podem não fornecer a configuração ideal de SVM para aplicações em sensoriamento remoto.

Após testes empíricos, Costa, Zeilhofer e Rodrigues (2010) optaram em utilizar uma Função de Base Radial (RBF). Nascimento *et al* (2009) utilizou a Função de Base Radial, pois, em sua pesquisa, foi constatada que vários autores (nomeadamente, Brown, Gunn e Lewis (2000), Huang *et al* (2002), Melgani e Bruzzone (2004))

afirmaram que esta função apresenta os melhores resultados na separação ótima de classes. Petropoulos, Arvanitis e Sigrimis (2012) também utilizaram a Função de Base Radial (RBF) para realizar a classificação de pares SVM. Mountrakis, Im e Ogole (2011) afirmam que o SVM com RBF resultou em um maior desempenho em relação a velocidade de convergência; precisão melhor na classificação dos dados do que um SVM com polinomial. Ainda, quando as performances das funções Kernel foram analisadas, Kavzoglu e Colkesen (2009) constataram que o Kernel de Função de Base Radial produziu resultados mais precisos do que o Kernel polinomial.

Para o caso de reconhecimento de padrões, segundo Burges (1998), SVM têm sido utilizados para o reconhecimento de escrita à mão e de objetos, identificação de voz, detecção de face em imagens, e categorização de texto. Na maior parte destes casos, o desempenho do SVM, isto é, as taxas de erro nos conjuntos de teste foram significativamente menores do que as taxas dos métodos concorrentes. Mountrakis, Im e Ogole (2011) afirmam que, mesmo o método SVM não sendo muito popular, nos últimos anos têm havido um aumento significativo em estudos sobre SVM em problemas de sensoriamento remoto.

Pesquisas recentes indicaram o potencial considerável de SVM para a classificação supervisionada de dados de sensoriamento remoto. Estudos comparativos têm mostrado que a classificação por um SVM pode ser mais preciso do que redes neurais e árvores de decisão, bem como classificadores probabilísticos convencionais, tais como a classificação máxima verossimilhança (FOODY e MATHUR, 2004 b).

Nascimento *et al* (2009) concluiu em seu trabalho que a classificação de imagens CCD-CBERS-2 por meio do SVM foi considerada muito boa. Outros estudos também verificaram que o desempenho de SVM é geralmente tão bom, ou melhor, que soluções com RNA (HEARST *et al.*, 1998 apud BROWN, GUNN e LEWIS, 1999). Outros trabalhos que comparam o desempenho do SVM, com outros classificadores convencionais podem ser encontrados na literatura, como: Andreola e Haertel (2009), Kavzoglu e Colkesen (2009), Alonso e Malpica (2010) e Mountrakis, Im e Ogole (2011), apontando que SVM parecem ser uma boa alternativa para as técnicas de classificação convencionais.

Foody e Mathur (2004) relata que SVM têm um potencial considerável para a classificação de dados de sensoriamento remoto. Em geral, as classificações SVM são

mais precisas do que as classificações semelhantes. A precisão das classificações foi positivamente relacionada ao tamanho do conjunto de treinamento, com a precisão das classificações aumentando significativamente à medida que o tamanho do conjunto de treinamento aumentou de 15 para 100 exemplos por classe. Embora uma classificação SVM seja eficaz com base num pequeno número de amostras, uma grande amostra de treino pode ser necessária para garantir que os dados de formação de margens adequadas sejam incluídos.

Em Petropoulos, Arvanitis e Sigrimis (2012), tomando-se como base os resultados da avaliação de precisão, geralmente SVM superaram o classificador RNA em exatidão global e em classes individuais. Sendo esta melhor precisão atribuída, pelos autores, à capacidade do SVM identificar um hiperplano ótimo para a separação de classes, o que classificadores como RNA podem não ser capazes de localizar.

2.4 Modelagem dos Caminhos do Escoamento Superficial

Para melhor dimensionamento de projetos e investimentos associados, é necessário que modelos de escoamento se assemelhem à realidade. No entanto, uma validação de um modelo é extremamente difícil de executar. Ainda, é incerto quais modelos oferecem os resultados mais precisos. Embora esteja claro que alguns modelos de escoamento possam ter um melhor desempenho que outros (CROMBEZ, 2008).

Para Buarque *et al* (2009), uma das primeiras etapas na análise do terreno é a definição das direções do escoamento. A partir das direções de escoamento são calculados outros parâmetros ou variáveis de interesse hidrológico, como a área de drenagem a montante de cada célula, delimitação de sub-bacias, definição da rede de drenagem, determinação de comprimentos e declividades de trechos de rio, etc.

Algoritmos de determinação do escoamento são uma ferramenta de análise do terreno, utilizadas para modelar a transferência de água, sedimentos, contaminantes, ou nutrientes através da paisagem. Cada algoritmo define como o fluxo de um determinado ponto, ou área, será distribuído para regiões vizinhas (CROMBEZ, 2008).

Crombez (2008) também afirma que algoritmos de determinação do fluxo são a essência da análise do terreno, por computarem dois atributos essenciais que são: a

direção do fluxo e a acumulação do fluxo. Direções do fluxo são definidas em cada local do terreno, para depois se determinar o fluxo global da água através da paisagem. A acumulação do fluxo quantifica a área contribuinte, determinante para quantificação de água que passa por estes locais. Direção do fluxo e acumulação do fluxo são atributos do terreno que, em muitos casos, são utilizados para modelar processos hidrológicos, geomorfológicos e até biológicos. O cálculo de áreas contribuintes, baseado em MDE, é uma das principais questões na análise digital do terreno, e tem influência marcante sobre uma ampla gama de aplicações, tais como análise hidrológica, erosão do solo e geomorfologia (QIN e ZHAN, 2012). A área contribuinte para cada pixel pode ser estimada como o produto do número de pixels que contribuem com drenagem para este pixel e a área do pixel (TARBOTON, 1997).

Vários algoritmos de mapeamento do fluxo foram implementados em SIG, ou outros softwares de modelagem específica.

Fundamentalmente, estes algoritmos determinam a maneira pela qual o fluxo de saída a partir de uma determinada célula será distribuído para uma ou mais células vizinhas. A escolha do algoritmo pode influenciar no cálculo da área contribuinte, previsões de acumulação de fluxo e outros atributos hidrológicos, sendo também influenciados pela resolução dos Modelos Digitais de Elevação (WILSON *et al.*, 2008).

Os algoritmos de determinação do fluxo tem a finalidade de montar uma grade digital onde o valor de cada pixel desta grade representa a direção do escoamento da água. Sendo que esta direção será aquela que levará a água para o pixel vizinho de menor valor de altitude (MENDES e CIRILO (2001) apud BRANDÃO e SANTOS (2009)).

Os primeiros métodos para definir direções de escoamento a partir de um MDE foram descritos ao longo da década de 80 por autores como O'Callaghan e Mark (1984), Mark (1984) e Jenson e Domingues (1988). Durante os anos seguintes, algumas modificações foram sugeridas, ou outros métodos desenvolvidos, como a possibilidade de existir escoamento em múltiplas direções como em Quinn *et al.*, 1991 e Tarboton, 1997.

Os algoritmos podem ser classificados em: de direção única ou de direção múltipla. Um algoritmo de direção única transfere todo o fluxo da célula central para um vizinho de elevação mais baixa, enquanto que, para os algoritmos de direção

múltipla, o fluxo pode fluir fracionadamente para vários vizinhos (ERSKINE *et al.*, 2006).

Nos métodos que determinam uma única direção do fluxo, normalmente, a determinação da direção ocorre por um critério de maior declividade. A declividade de uma linha ligando a célula central a cada uma de suas vizinhas é calculada e é identificada a célula vizinha para a qual a declividade é máxima (MARK, 1984; O'CALLAGHAN e MARK, 1984 apud BUARQUE *et al.*, 2009).

Crombez (2008) afirma que algoritmos de direção única são modelos que imitam padrões de fluxo convergentes e são eficazes na identificação de redes de drenagem. Devido a sua simplicidade e eficiência computacional, são populares em muitos softwares de SIG. No entanto, são evitados em projeto de modelagem hidrológica por apresentarem fluxos inconsistentes. Já os algoritmos que permitem o fluxo para diversos vizinhos, são mais sofisticados, pois permitem fluxos convergentes e divergentes, sendo esta característica de dispersão do modelo desejável em muitas análises. Porém, apresentam maiores custos computacionais. A escolha do algoritmo utilizado é importante, pois afeta o cálculo da área contribuinte, área de abrangência, e vários outros atributos topográficos. Sendo assim, é importante analisar as saídas esperadas e dados disponíveis para melhor escolha do algoritmo.

Brandão e Santos (2009) relatam que na grande maioria dos softwares utilizados em modelagem hidrológica para extração automática de características morfométricas (ArcHydro, SAGA, MapWindows, SPRING), todo o procedimento é baseado num algoritmo determinístico de direção única do fluxo, de oito direções possíveis (D8).

O conceito do D8 tem a desvantagem de resultar do processo de discretização do fluxo em somente uma das oito possíveis direções, separados por 45°. Isto tem motivado o desenvolvimento de outros métodos que possam inferir na múltipla direção de fluxos, métodos de direcionamento aleatório e métodos tubulares de fluxo (BRANDÃO e SANTOS 2009).

Crombez (2008) complementa dizendo que o algoritmo Rh8 realiza sua rotina de forma semelhante ao algoritmo D8, com a exceção de que incorpora um fator aleatório para atribuição do fluxo. Este ainda é atribuído para apenas um de seus vizinhos, no entanto, em vez de usar sempre a direção de descida mais íngreme, a direção é selecionada aleatoriamente entre os vizinhos mais baixos.

Segundo Tarboton (1997) o método de direções múltiplas do fluxo (MS) também tem sido sugerido como uma tentativa de resolver as limitações de D8. O MS atribui a cada vizinho mais baixo uma fração do fluxo. Endreny e Wood (2003) declaram que tanto o D8, quanto o MS, utilizam o método do vizinho mais próximo para determinar o caminho mais íngreme de descida, mas cada um usa abordagens diferentes de alocação do fluxo. O algoritmo D8 não permite bifurcação, enquanto o MS, em contraste, distribui o fluxo para todos os vizinhos mais baixos em elevação.

Já os algoritmos que permitem o fluxo para diversos vizinhos são mais sofisticados, pois permitem fluxos convergentes e divergentes, sendo esta característica de dispersão desejável em muitas análises. Porém, apresentam maior custo computacional. São exemplos os algoritmos de direção múltipla: MS (*Multiple Directions based on Slope*) (Quinn *et al.*, 1991), 2D-Lea (de Lea, 1992), DEMON (Digital Elevation MOdel Networks de Costa-Cabral e Burges, 1994), e D-Infinito (Tarbaton, 1997), mas utilizam regimes distintos para calcular o vetor de fluxo e são discutidos brevemente a seguir.

O algoritmo MS atribui a cada vizinho mais baixo uma fração do fluxo e tem como vantagem permitir a bifurcação do escoamento superficial.

De acordo com Wilson *et al* (2008), o algoritmo de Lea (1992) baseia-se na geração de um vetor gerado sobre a inclinação de uma superfície. O fluxo move-se através de uma superfície plana na direção da inclinação mais acentuada, semelhante a uma bola rolando. Esta abordagem divide-se em duas partes. Na primeira, são gerados os planos para representar a superfície de cada célula, usando as elevações estimadas dos quatro cantos de cada célula. Na segunda parte, o vetor de declividade é então calculado, com incrementos de 1° (diferente do D8 que a análise ocorre a cada 45°). A direção do fluxo é construída através da aplicação repetida do algoritmo, até que o fluxo saia do MDE. Segundo Crombez (2008), Lea (1992) descreve o fluxo como se houvesse uma bola rolando num plano, partindo do centro de cada pixel. Cada célula na grade é representada como um plano gerado a partir dos cantos de cada pixel. Este procedimento tem a vantagem de especificar direções contínuas de fluxo, com ângulo entre 0 e 2π . Este conceito único foi, mais tarde, incorporado por Costa-Cabral e Burges (1994) na elaboração de um novo algoritmo, denominado DEMON.

Segundo Erskine *et al* (2006) o algoritmo de Costa-Cabral e Burges (1994) é uma extensão do método de Lea (1992), em que são gerados planos em função dos quatro cantos do pixel, e com isso retirada a inclinação e direção do fluxo. O fluxo é assumido ser uniforme sobre a área do pixel e o mesmo é particionado entre os vizinhos do sentido da declividade. Este algoritmo considerado bidimensional cria “tubos de fluxo” (*stream tubes*) conceituais, onde a largura desses tubos pode aumentar em função do terreno ser divergente, diminuir se o terreno for convergente, ou ainda se manter constante em áreas planas. Crombez (2008) critica dizendo que esta abordagem complicada é raramente implementada em software SIG por causa das codificações elaboradas, principalmente para garantir o sucesso em todas as situações possíveis. De acordo com Tarboton (1997), Costa-Cabral revelou através de uma comunicação pessoal, em 1995, que o código para calcular a área contribuinte para DEMON não está disponível porque é "difícil de programar e cheio de casos especiais".

Tarboton (1997) ao criar o método do Dinfinito, reconhece que os métodos de fluxo no plano de Lea (1992) e Costa-Cabral e Burges (1994) são atraentes por serem determinísticos ao detectarem a direção do fluxo. Entretanto, estão suscetíveis a erros, principalmente devido à geração de um plano pelos quatro cantos do pixel. O melhor ajuste do plano não é determinado por 4 pontos no plano, os quatro cantos do pixel, e sim por apenas 3 pontos. Isto pode levar a problemas inconsistentes na determinação da direção do fluxo, sendo um problema tanto do método de Lea (1992), quanto de Costa-Cabral e Burges (1994) (CROMBEZ, 2008).

Wilson *et al* (2008) acrescenta que é evidente que cada algoritmo produza resultados diferentes, devido as suas abordagens distintas. Ainda, Erskine *et al* (2006) diz que padrões de drenagem irrealistas estão presentes em todos os algoritmos, em algum grau, mas são mais pronunciados em algoritmos de única direção.

A Figura 4 traz um esquema com as diferenças entre as abordagens dos algoritmos.




Figura 4 - Esquema do cálculo do fluxo realizado pelo D8, MS, DInfinito.

Fonte: adaptado de ENDRENY e WOOD, 2003.

Outro conceito importante é que os modelos são tão precisos como os dados que os alimentam, tanto na resolução planimétrica como altimétrica. No estudo realizado por Raaflaub (2002) citado por Crombez (2008), determinou-se a sensibilidade dos erros de superfície produzem nas redes de drenagem definidas. Foi comprovado que os algoritmos que utilizam a metodologia de vizinho mais próximo são os que geram redes melhor definidas e tem maior sensibilidade aos erros.

De acordo com Qin e Zhan (2012) para o cálculo do caminho do escoamento é usado, geralmente, um algoritmo de pré-processamento do MDE para preencher as depressões e áreas planas. Estas depressões e áreas planas existem em MDE reais, tanto por causa das condições do terreno real ou erros introduzidos durante a produção do MDE. Estas características reais ou falsas em um MDE fará com que os algoritmos de direção do fluxo cheguem a resultados não satisfatórios. As falsas depressões constituem um problema importante nos modelos de determinação do escoamento, pois interrompem o escoamento superficial. Devem ser removidas, portanto, para se ter um MDE consistente sob o ponto de vista hidrológico. Essas imperfeições são muito frequentes nos MDE e derivam-se de erros presentes nos dados de entrada ou introduzidos no processo de interpolação (Brandão e Santos, 2009)

Segundo Erskine *et al* (2006) vários artigos têm demonstrado diferenças entre algoritmos de direção única e de direções múltiplas em redes de drenagem, na localização de voçorocas, na modelagem de erosão e taxa de sedimentação, em padrões espaciais de áreas saturadas, e as distribuições estatísticas dos atributos do terreno. Erskine *et al* (2006) ainda complementa que atributos do terreno, baseados na área contribuinte também são amplamente utilizados em modelos hidrológicos distribuídos. Em seu estudo foram comparados quantitativamente cinco algoritmos (D8 [O'Callaghan

e Mark, 1984], Rh8 [Fairfield e Leymarie, 1991], MFD [Freeman, 1991], DEMON [Costa-Cabral e Burges, 1994], e Dinfinito [Tarboton, 1997].), utilizando como base o DEM de campos agrícolas de 63 e 109 ha no Colorado. As maiores diferenças foram encontradas em regiões de cumes e encostas laterais e estas diferenças diminuíram onde o terreno se tornou mais convergente. O método D8 produziu fluxos retos e paralelos ao longo de encostas. O método Rh8 produziu caminhos mais tortuosos. Os algoritmos DEMON e Dinfinito foram muito semelhantes aos de única direção em regiões de fundo de vale, enquanto o MS apresentou excessiva divergência no fluxo. Entretanto, ao se comparar com as observações de campo, o algoritmo MS apresentou resultados globais mais consistentes. Uma forma de avaliação dos algoritmos foi a utilização da frequência acumulada da área, em $\log(A)$, e plotados conjuntamente. Foi concluído que as diferenças entre os algoritmos ficam menos distintas com o aumento da resolução do MDE, ou seja, houve menor percepção das diferenças dos algoritmos quando a resolução do MDE era de 30 metros do que quando a resolução era de 5 metros. Os algoritmos de direção única apresentaram menores valores acumulados de $\log(A)$, isto pela falta de divergência dos algoritmos.

Os principais resultados obtidos por Erskine *et al* (2006) foram:

- os caminhos de drenagem determinados pelos algoritmos de direções múltiplas (MFD, DEMON, Dinfinito) foram os mais consistentes com os padrões visuais;
- as diferenças entre os algoritmos são visíveis na comparação da distribuição de frequência, $\log(A)$, para todas as resoluções, mas são mais evidentes em resoluções menores, por exemplo, grades de 5 metros.
- as distribuições de frequência para algoritmos de múltipla direção foram muito semelhantes (MDF e DEMON), mas bem diferentes das distribuições de direções únicas (D8 e Rh8), e a distribuição do Dinfinito se encontrou entre estes dois padrões.
- as maiores diferenças relativas se deram em áreas divergentes. O aumento do tamanho das células diminuiu essas diferenças.

3 Materiais e Métodos

Neste capítulo são descritos os materiais e métodos utilizados neste trabalho. Entre os materiais, são apresentadas as áreas de estudo e os dados relativos às mesmas, assim como softwares e configurações dos computadores usados. Na seção dos métodos é apresentada a metodologia utilizada.

3.1 Materiais

Neste trabalho foram utilizadas duas áreas de estudo, com diferentes tipos de dados, de fontes distintas, que são apresentadas na seção 3.1.1. Os softwares utilizados são listados na Tabela 2.

Tabela 2 – Softwares e etapas em que foram utilizados.

Software	Etapas
MATLAB 7.10 (2010)	<ul style="list-style-type: none"> • Pré-tratamento dos dados; • Métodos de Filtragem: <ul style="list-style-type: none"> - Morfologia Matemática; - Formação de Pirâmide; • Geração MDSn; • Classificação Digital de Imagens; • Simulação dos Caminhos do Escoamento.
ALDPAT 1.0	<ul style="list-style-type: none"> • Métodos de Filtragem: <ul style="list-style-type: none"> - Morfologia Matemática; - Declividade; - TIN; - ETEW.

Para o processamento, foram utilizados dois computadores com diferentes configurações. O primeiro, no qual se deu quase todo o processamento foi um computador com processador Intel Core 2 Duo, de 2,10 GHz, 3,00 GB de memória RAM e sistema operacional de 64 Bits. O segundo, utilizado exclusivamente para a classificação da área da Água Verde / Rebouças com o classificador SVM, foi um computador com processador Intel Core i7, de 3,40 Hz, 16 GB de memória RAM e sistema operacioanl de 64 Bits.

3.1.1 Áreas de Estudo

Para este trabalho foram utilizadas duas áreas de estudo. A primeira trata-se da região do Campus Centro Politécnico, da Universidade Federal do Paraná, situada em Curitiba – Paraná – Brasil, apresentada na seção 3.1.1.1. A segunda trata-se de uma área mais densamente urbanizada, com maior variedade de materiais e cobertura do solo. Esta área está compreendida entre os bairros Água Verde / Rebouças, na cidade de Curitiba – Paraná – Brasil, apresentada na seção 3.1.1.2. A localização geográfica destas áreas é mostrada na Figura 5.

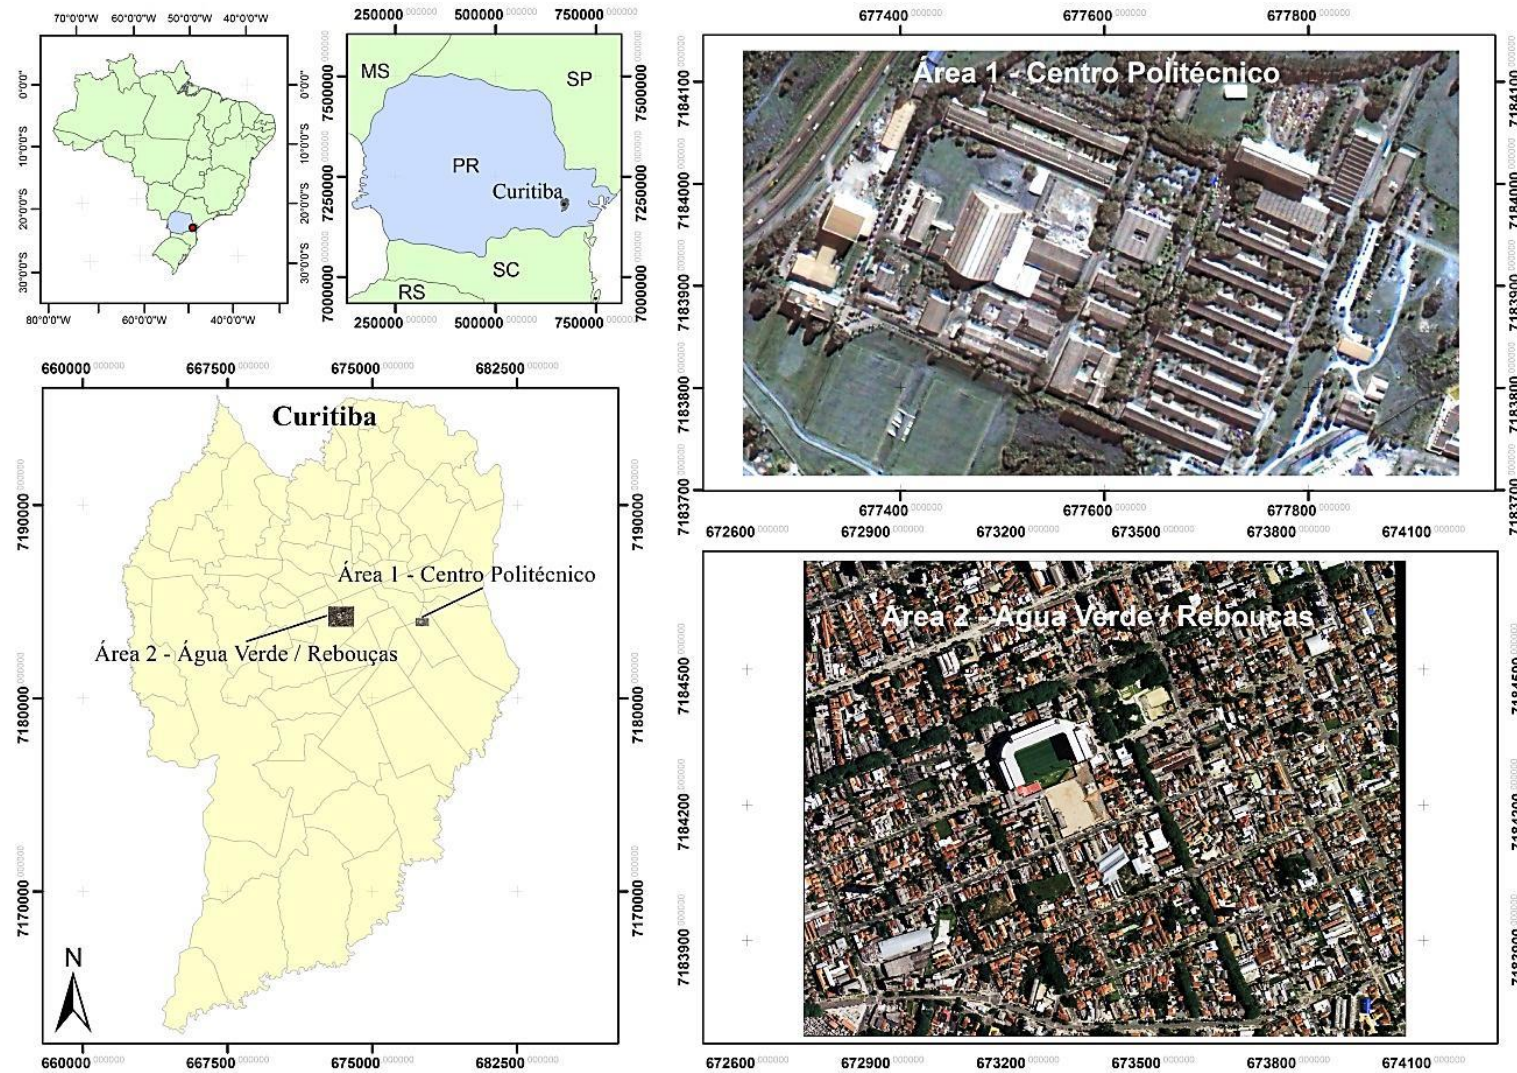


Figura 5– Localização das Áreas de Estudo.

3.1.1.1 Centro Politécnico – UFPR

Para a área do Campus Centro Politécnico da Universidade Federal do Paraná, estão disponíveis informações espectrais da região do visível e do infravermelho próximo, assim como os dados do levantamento *Laser Scanner*.

A imagem espectral é mostrada na Figura 6, (a) contendo informações na região do espectro visível e (b) contendo informações na região do verde, vermelho e infravermelho próximo. Esta é uma imagem do sensor Quickbird II, de 2002, com a plataforma em órbita a 450 km de altitude, com resolução espacial de 0,7 metros, cedida pela empresa CetilGeo.

Os dados de altimetria do *Laser Scanner*, já em formato *raster* ou imagem, são apresentados na Figura 7; e a intensidade de retorno do *Laser Scanner* é apresentada na Figura 8, onde os valores digitais foram contrastados para fins de visualização. Estes dados *Laser Scanner* foram obtidos pelo sensor ALTM 2050, em 2003, altura de voo de 1000 metros, com resolução espacial de 0,7 metros, cedidos pelo Instituto de Tecnologia para o Desenvolvimento - LACTEC.




Figura 6 – Informação espectral do Campus Centro Politécnico – UFPR (a) combinação do visível (b) combinação com infravermelho.




Figura 7 - Dados de altimetria do *Laser Scanner* do Campus Centro Politécnico – UFPR.



Figura 8 - Intensidade de retorno do *Laser Scanner* do Campus Centro Politécnico – UFPR.

3.1.1.2 Água Verde / Rebouças

Para esta área de estudo, estão disponíveis dados de *Laser Scanner* e imagem na região do espectro do visível (RGB) cedidos pela empresa Esteio Engenharia e Aerolevantamentos.

A imagem do RGB, apresentada na Figura 9, são fotografias aéreas obtidas usando uma câmera do tiro Cyber Shot DSC-s40, com resolução espacial de 0,30 metros.

Na Figura 10 observam-se os dados *Laser Scanner* de altimetria da área, com resolução de 0,50 metros. E, na Figura 11, são apresentados os dados correspondentes à intensidade do retorno do pulso do *Laser Scanner*. Estes dados foram adquiridos por um varredor 2025 de Optech ALTM.



Figura 9 - Imagem da região do espectro do visível de parte dos bairros Água Verde / Rebouças – Curitiba –PR – BR.




Figura 10 - Dados *Laser Scanner* de altimetria de parte dos bairros Água Verde / Rebouças – Curitiba – PR – BR.




Figura 11 - Intensidade do retorno do pulso do *Laser Scanner* de parte dos bairros Água Verde / Rebouças – Curitiba –PR – BR.

3.2 Métodos

A solução proposta nesta pesquisa se baseia num conjunto de métodos para a derivação de informação a partir de imagens de satélite ou fotografias aéreas e dados *Laser Scanner*, com objetivo final de simular os caminhos do escoamento superficial sobre as áreas de estudo, seção 3.1.1, pág. 49. A Figura 12 apresenta um fluxograma da metodologia deste trabalho.

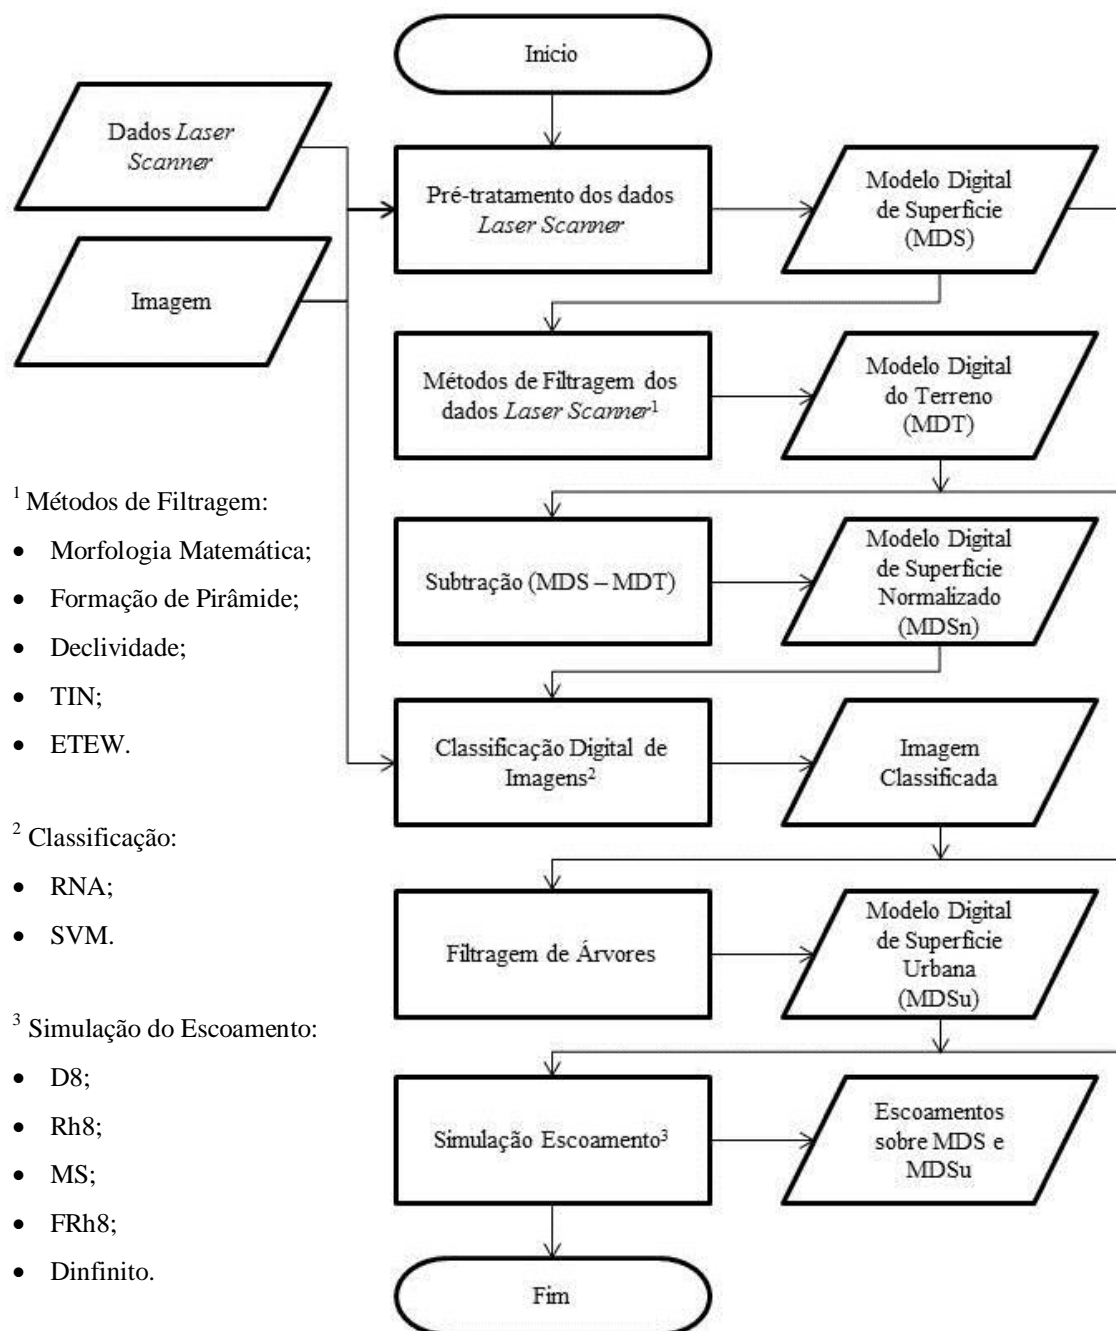


Figura 12 – Fluxograma da metodologia deste trabalho, com a descrição dos métodos de filtragem, classificadores e algoritmos de simulação de escoamento utilizados.

Como apresentado no fluxograma - Figura 12 - para alcançar o objetivo final de simulação dos caminhos do escoamento, alguns processos anteriores foram necessários. Estas etapas serão melhor explicadas nas seções seguintes. Porém, para facilitar a compreensão da necessidade destes processos e da disposição dos mesmos na ordem apresentada no fluxograma e seções seguintes, pode-se descrever a metodologia, sucintamente, como segue.

Para simulação dos caminhos do escoamento superficial, é necessária a identificação de possíveis obstáculos que não estarão diretamente em contato com o fluxo, tais como árvores ou redes de distribuição de energia. A informação altimétrica destes obstáculos é então substituída pela informação altimétrica do terreno. As redes de distribuição de energia são retiradas já nos processos de pré-tratamento de dados. A filtragem das árvores é um pouco mais complexa, e envolve a identificação das mesmas, através dos classificadores. Com isso, tem-se o Modelo Digital de Superfície Urbana (MDSu), onde os objetos que não estão em contato direto com o fluxo do escoamento superficial foram retirados.

Os classificadores são identificadores de padrões, onde um conjunto de dados é utilizado para treinamento e aprendizado dos padrões destes alvos. No caso deste trabalho, as informações utilizadas na classificação são: as informações espectrais, os dados de altimetria e de intensidade obtidos por *Laser Scanner*. Como demonstrado na Figura 1, pág. 24, em função da variação altimétrica do próprio relevo, pode ser possível que existam áreas de vegetação rasteira com altura maior que árvores, prédios com altura menor que casas, ou mesmo prédios e casas com cota menor que o próprio terreno. Para que esta informação altimétrica possa ser utilizada, é necessária que esta influência do relevo seja retirada. Para isso é feita a filtragem dos dados de elevação, normalizando as alturas.

Para que a influência do terreno seja eliminada, ou amenizada, são utilizados métodos para a filtragem dos dados que não pertencem ao terreno. Estes métodos tentam identificar dados que não pertencem ao terreno, basicamente utilizando o conceito de que a variação da declividade no terreno é suave, enquanto que esta mesma variação entre o terreno e um objeto sobre ele é acentuada. Após a identificação destes pontos do terreno, os dados que não pertenciam ao terreno podem ser preenchidos por interpolação, gerando o Modelo Digital do Terreno (MDT). Com a subtração do

Modelo Digital de Superfície (MDS), obtido dos dados *Laser Scanner*, com o MDT, restam apenas as feições com altura diferente, ou seja, os objetos sobre o terreno, ou o Modelo Digital de Superfície Normalizado (MDSn).

Sendo assim, de forma a melhor detalhar cada uma das etapas da metodologia, são apresentadas as seções seguintes.

3.2.1 Pré-tratamento dos dados

Inicialmente, os dados *Laser Scanner* estão em um arquivo de formato *ascii*, com coordenadas tridimensionais e de intensidade de retorno do pulso *laser*. Estes dados não necessitam estar igualmente espaçados e distribuídos, podendo estes ser organizados em uma grade, formato *raster* ou imagem. Neste trabalho, a grade gerada é em função da resolução da imagem espectral. Caso a imagem espectral possua melhor resolução que os dados *Laser Scanner*, esta imagem é degradada para sempre utilizar como base a pior resolução.

A geração desta grade segue a metodologia descrita por ARAKI (2005), onde a grade regular é gerada, inicialmente vazia, sendo preenchida por valores do levantamento *Laser Scanner*. É aplicada em seguida morfologia matemática, de forma a preencher espaços ainda vazios na grade. A morfologia matemática executada nesta fase é de fechamento (dilatação seguida de erosão). Caso, ao final deste processo, ainda existam lugares da grade sem informação, estes são preenchidos com o valor do pixel mais próximo de menor elevação.

Ainda no pré-tratamento dos dados, foi aplicada novamente morfologia matemática a fim de eliminar possíveis ruídos ou elementos como redes de distribuição de energia. Desta vez, o operador de morfologia matemática executada é a de abertura (erosão seguida de dilatação).

Tanto na execução da morfologia matemática de fechamento como na de abertura, foi utilizado um operador quadrado, de tamanho de três por três pixels.

Ao final destas etapas, se tem um Modelo Digital de Elevação (MDE), ou de Superfície (MDS) gerado a partir dos dados *Laser Scanner*.

A última etapa do pré-tratamento dos dados é o georreferenciamento das imagens, utilizando a grade *Laser Scanner* como referência. Com isso, é determinada a área de intersecção dos dados, ou, em outras palavras, é verificada a área em que se tem tanto a informação espectral como os dados *Laser Scanner*.

Todos esses processos de pré-tratamento dos dados foram implementados pelo autor no software MATLAB.

3.2.2 Métodos de Filtragem de dados *Laser Scanner*

Com a finalidade de se escolher o método mais apropriado, um estudo comparativo foi conduzido. Este consiste em aplicar diferentes métodos de estimativa do MDT, partindo da nuvem de pontos ou de uma grade regular interpolada a partir desta nuvem. Após a filtragem dos dados, os pontos da grade que ficaram sem informação foram preenchidos através de interpolação bilinear, utilizando os pontos que restaram como base para a geração do MDT.

Os métodos de filtragem (seção 2.2, pág. 23) que serão avaliados, apresentados a seguir, são:

- Morfologia Matemática (seção 3.2.2.1, pág. 59);
- Formação de Pirâmide (seção 3.2.2.2, pág. 61);
- Declividade (seção 3.2.2.3, pág. 62);
- TIN (seção 3.2.2.4, pág. 63);
- ETEW (seção 3.2.2.5, pág. 63).

3.2.2.1 Morfologia Matemática

Segundo Rottensteiner e Briese (2002), os filtros morfológicos de abertura são comumente usados na determinação do Modelo Digital do Terreno (MDT).

Para Zhang *et al.* (2003), este filtro de morfologia matemática é usado para remover objetos não pertencentes ao terreno. Toma-se como base que a altura de árvores, carros e edifícios é geralmente mais elevada do que os pontos circundantes.

Completa dizendo que esta metodologia de operação de morfologia matemática pode ser usada para filtrar os dados *Laser Scanner* e obter o MDT.

A combinação de erosão e dilatação forma as operações de abertura e fechamento, que são aplicados para filtrar dados de *Laser Scanner*. A operação de abertura consiste na utilização da erosão de um conjunto de dados, seguido por uma dilatação, enquanto que a operação de fechamento é a utilização de dilatação seguida de erosão. Quando se aplica a operação de abertura, no resultado da erosão, objetos de tamanhos menores que o operador morfológico são removidos, enquanto que a dilatação trata de restaurar as formas maiores que o operador. Sendo assim, o processo de abertura tem a capacidade de preservar as características de objetos maiores que o operador morfológico (ZHANG *et al.*, 2003).

A seleção do tamanho do elemento estruturante para a filtragem de objetos é determinante para o sucesso do método. Se o tamanho do elemento estruturante for muito pequeno, a maior parte dos pontos será preservada, permanecendo também objetos (mesmo os que não pertencem ao terreno) de tamanho maior que o operador. Com um tamanho muito grande, o filtro tende a remover pontos do terreno. Sendo assim, o tamanho do elemento estruturante do operador morfológico tem que ser pequeno o suficiente para preservar os pontos do terreno, mas grandes o suficiente para remover edifícios, carros e árvores. Infelizmente, este tamanho é relativo e dependente da área, não existindo um padrão geral (ZHANG *et al.*, 2003).

Chang *et al* (2008) argumenta que elementos estruturantes muito pequenas podem preservar objetos como construções, enquanto que elementos estruturantes muito grandes podem corromper o próprio terreno, cortando colinas ou topos de morros. Para evitar este conflito, Kilian *et al* (1996) apud Zhang *et al* (2003), propõem a aplicação das operações com diferentes tamanhos. A vantagem de aumentar o elementos estruturantes de forma linear é que, gradualmente, as características do terreno vão sendo preservadas.

O processo de filtragem é altamente automático e requer pouca intervenção humana, o que pode ser desejável tratando-se de grandes quantidades de dados. No entanto, este método não é perfeito, sendo possíveis alguns erros de comissão ou omissão (ZHANG *et al.*, 2003).

Neste trabalho foram utilizados diferentes métodos de morfologia matemática, utilizando o software ALDPAT ou implementados em MATLAB. Portanto, para diferenciação, quando for referido na seção dos resultados ou apêndices como simplesmente morfologia matemática, estará sendo referenciado o método implementado no MATLAB; e quando for sobre o método do software ALDPAT, o nome deste software será citado.

Para verificar a influência dos elementos estruturantes, foram analisados também diferentes tipos, baseados em formato quadrado, circular e linear.

3.2.2.2 Formação de Pirâmide

O método de pirâmide de imagens compreende duas etapas: a redução da resolução, por um agrupamento sistemático de pixels, e então o retorno à resolução original. Estas duas etapas são controladas por parâmetros, que determinam a seleção dos valores a serem atribuídos aos pixels. O método em geral não possui um número fixo de parâmetros que devem ser utilizados, mas este número deve ser suficientemente grande para que o filtro possa ser utilizado em vários tipos de terrenos, com diferentes características e peculiaridades, e suficientemente pequeno para facilidade de entendimento e ajuste desses parâmetros (COELHO *et al.*, 2002).




Figura 13 – Esquema de funcionamento do método de pirâmide.

A Figura 13 ilustra como é realizado o processamento, onde como exemplo foi tomado um grid de 9x9 pixels sujeito a duas reduções de resolução passando sucessivamente para 3x3 pixels e finalizando em 1x1 pixel.

No último nível da pirâmide, espera-se quem não existam mais pixels com objetos. Esta aproximação é comparada pixel a pixel com o nível imediatamente inferior da pirâmide. A comparação é controlada pelos parâmetros, sendo repetido até que seja comparada com a imagem original armazenada no primeiro nível. Quando o valor das alturas entre as duas superfícies são comparados, podem ser detectados os pixels que pertencem a objetos, por estes gerarem uma diferença de altura relativamente grande. É dado então um valor limite de diferença de altura a ser tolerado, acima do qual o objeto será filtrado e tomada a informação do pixel que não possuía este objeto (COELHO *et al.*, 2002).

Segundo Rottensteiner e Briese (2002), as etapas desta metodologia para filtragem utilizando pirâmides de imagens são:

- 1 – Criar as pirâmides de dados, através da seleção dos pontos mais baixos em uma malha de grade regular;
- 2 – Realizar uma interpolação para gerar o MDT, gerando imagens de resoluções menores;
- 3 – Comparar o MDT entre as imagens formadas, até a imagem de maior resolução (a imagem original), aceitando-se apenas que pertencem ao terreno, com uma certa tolerância.

Porém, Coelho *et al* (2002) alerta que o método é capaz de extrair com eficiência a vegetação e as edificações, mas elimina também partes do terreno que, com a redução da resolução da imagem, podem apresentar-se como objetos.

Este método foi programado pelo autor no software MATLAB.

3.2.2.3 Declividade

Este método considera a variação local da declividade como parâmetro para classificação dos pontos como sendo do terreno ou não. É criada uma grade regular,

onde os pontos são organizados, em função das suas coordenadas x e y . Caso mais de um ponto de medição *Laser Scanner* esteja sobre determinada posição na grade, o ponto de menor altitude é selecionado para preencher o valor desta célula. É feita uma comparação entre um determinado ponto, de menor altitude na imagem (p_0), com outros pontos (p_j) dentro de um determinado raio (r), sendo considerado este ponto p_j como terreno se o valor da declividade entre ele e p_0 estiver abaixo de um limite de declividade (S) estipulado (ZHANG e CUI, 2007).

Este método está implementado no software ALDPAT.

3.2.2.4 TIN

O Método de filtragem baseado no princípio TIN (*Triangulated Irregular Network* - Rede de Triangulação Irregular) utiliza a geração de uma malha adaptável de triângulos irregulares formados pelos pontos de medição *Laser Scanner*.

Estes pontos de medição são arranjados em uma grade de quadrados regular, onde o tamanho destes quadrados tem que ser maior que o maior objeto. O valor a preencher o valor do quadrado é a altura do menor ponto de medição presente neste quadrado. A seguir, o TIN é gerado e é comparada a distância dos pontos originais do *Laser Scanner* com a superfície do triângulo gerado. Se a distância for menor que um limite pré-definido, este ponto é considerado como sendo do terreno. A cada iteração, novos triângulos são formados utilizando os pontos já considerados como terreno previamente, e, novamente, calculadas as distâncias entre os dados originais do *Laser Scanner* com a superfície dos novos triângulos (ZHANG e CUI, 2007).

Este método está implementado no software ALDPAT.

3.2.2.5 ETEW

O método ETEW (*Elevation Threshold with Expand Window* – Limite de elevação com janela expansiva) utiliza o princípio de uma janela expansível, com um

limite de elevação, para identificar grandes variações de elevação em uma área (ZHANG e CUI, 2007).

O conjunto de dados é subdividido em conjuntos de células quadradas, sendo descartados todos os pontos que não possuem a altura mínima dessa região. No próximo passo, as células aumentam de tamanho, sendo que os pontos com altura maior que a altura mínima, mais um parâmetro de limiar de altura predefinido, são descartados. Este processo se repete até que se tenha cessado o descarte de pontos.

Este método está implementado no software ALDPAT.

3.2.3 Classificação Digital de Imagens

A ideia central é, neste caso, deduzir a presença de árvores, em função da variação dos valores digitais de uma imagem, que refletem as características espectrais dos objetos. Para isto, é necessário aplicar métodos de classificação (seção 2.3, pág. 26).

O problema da classificação digital de imagens pode ser resolvido de diferentes maneiras, por exemplo, adotando o pixel como unidade ou aplicando métodos de segmentação e classificação de segmentos. Neste trabalho, a classificação é feita com base no pixel.

Existem diferentes métodos para resolver o problema da classificação, neste trabalho são avaliados e comparados dois deles: o primeiro é baseado em Redes Neurais Artificiais (RNA) (seção 2.3.1, pág. 28) e o segundo aplica o conceito de *Support Vector Machine* (SVM) (seção 2.3.2, pág. 36).

Parte das imagens foi classificada pelo autor como sendo pixels representativos de árvores e não árvores, para cada uma das áreas de estudo. 50% destes pixels foram utilizados para a validação dos resultados obtidos pelos classificadores. Os outros 50% dos pixels considerados representativos foram utilizados para o treinamento dos classificadores. Para análise da influência das amostras de treinamento no processo de classificação, este grupo de pixels representativos (os outros 50% classificados pelo autor), foi dividido em 10 partes (de 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80% 90% e 100%). Ou seja, da amostra considerada representativa, 50% foram utilizados para validação dos resultados obtidos pelos classificadores, e 5%, 10%, 15%, 20%, 25%,

30%, 35%, 40%, 45%, 50% desta amostra representativa foram utilizadas no treinamento dos classificadores, para análise da influência do tamanho das mesmas.

Para a área do Centro Politécnico, foram classificados pelo autor 377.656 pixels, sendo utilizados 188.828 pixels para validação, e conjuntos de treinamento de 18.882, 37.765, 56.648, 75.531, 94.414, 113.296, 132.179, 151.062, 169.945, 188.828 pixels (os quais correspondem aos 5%, 10%, 15%, 20%, 25%, 30%, 35%, 40%, 45%, 50% destes 377.656 pixels classificados pelo autor).

Para a área da Água Verde / Rebouças, foram classificados pelo autor 579.518 pixels, com 289.759 para validação, e 28.975, 57.951, 86.927, 115.903, 144.879, 173.855, 202.831, 231.807, 260.783, 289.759 pixels para treinamento dos classificadores.

Estes dados foram organizados e apresentados na Tabela 3.

Tabela 3 – Quantidade de pixels amostrados, para as áreas de estudo.

	Centro Politécnico		Água Verde / Rebouças	
	Quantidade de Pixels	Percentual em relação ao amostrado	Quantidades de Pixels	Percentual em relação ao amostrado
Valor total amostrado	377.656	100%	579.518	100%
Conjuntos de Treinamento	18.882	5%	28.975	5%
	37.765	10%	57.951	10%
	56.648	15%	86.927	15%
	75.531	20%	115.903	20%
	94.414	25%	144.879	25%
	113.296	30%	173.855	30%
	132.179	35%	202.831	35%
	151.062	40%	231.807	40%
	169.945	45%	260.783	45%
	188.828	50%	289.759	50%
Validação	188.828	50%	289.759	50%

3.2.3.1 Redes Neurais Artificiais

Heermann e Khazenie (1992) afirmam que todos os nós da rede, exceto os de entrada, executam as mesmas funções: recolhem os valores transferidos da camada anterior e definem um resultado de saída. Os nós de entrada são determinados pelos dados de entrada. A função que recolhe os valores da camada anterior é dada por:

$$net_{pi} = \sum_j w_{ij} a_{pj} + bias_i$$

Onde w_{ij} representa o peso da ligação de um nó j da camada anterior com o nó i da camada atual, a_{pj} é o valor passado do nó anterior j do padrão p , e o $bias$ representa um termo independente, podendo ser considerado caso o nó atual i sempre possua ativação.

Este resultado então é encaminhado para a função de ativação para determinar sua ativação. Estas funções são não-lineares, para que se possa resolver problemas que uma rede linear não resolveria (HEERMANN e KHAZENIE, 1992).

Paola e Schowengerdt (1995) afirmam que para o algoritmo de treinamento *backpropagation*, a função de ativação deve ser diferenciável. A forma mais comum é a função sigmoide. Neurônios com funções sigmóides são, muitas vezes, utilizadas para problemas de reconhecimento de padrões, enquanto que neurônios de funções lineares são utilizados para problemas de ajuste de funções (BEALE, HAGAN e DEMUTH, 2011) Em Heermann e Khazenie (1992), assim como em Chettri, Crompt e Birmingham (1992), a função de transferência utilizada também foi a função sigmoide.

O treinamento consiste em apresentar dados de entrada com seus respectivos resultados esperados. O objetivo do treinamento é minimizar o erro entre o resultado esperado e o obtido pela rede. Para garantir a diminuição desse erro, os pesos entre as ligações são ajustados a cada iteração.

Heermann e Khazenie (1992) afirma que a fundamentação do algoritmo de aprendizado *backpropagation* é a otimização não-linear, de gradiente descendente, pelo somatório do quadrado da diferença entre os padrões apresentados a rede O_{pi} e o resultado obtido pela rede t_{pi} . O objetivo é então minimizar:

$$E = \sum_p \sum_i (t_{pi} - o_{pi})^2$$

Onde p são os padrões que se quer que a rede aprenda, e i o número de nós de saída da rede.

O treinamento da rede é concluído quando o erro é menor que um certo limiar, ou um número máximo de iterações é definido. É importante evitar o excesso de treinamento, conhecido como *overfitting*, uma vez que a rede pode classificar perfeitamente os dados de treinamento, mas não funcionar com os dados de teste (CHETTRI, CROMP e BIRMINGHAM, 1992).

Paola e Schowengerdt (1995) também relatam que o algoritmo *Backpropagation* não garante encontrar o erro mínimo global. De acordo com Jarvis e Stuart (1996), durante a fase de treinamento, as redes tendem a convergir para mínimos locais onde a resposta pode ficar aprisionada e não conseguir sair em direção ao mínimo global. Consequentemente, uma rede neural não pode garantir a melhor classificação geral (o mínimo global). Uma maneira de resolver este problema é adicionar algumas frações para alteração dos pesos. Este parâmetro, o momento, assim como a taxa de aprendizagem é definido no começo do treinamento, e deve ser determinado experimentalmente.

Outro parâmetro que influencia na eficiência de uma rede é a taxa de aprendizado. Ela é um valor que permite que os pesos da rede sejam ajustados conforme o erro relatado na saída (JARVIS e STUART, 1996) Uma taxa de aprendizagem muito pequena pode precisar de tempo de treinamento, enquanto que uma taxa muito grande pode degenerar o gradiente descendente de erro e fazer com que o erro aumente (PAOLA e SCHOWENGERDT, 1995).

Paola e Schowengerdt (1995) também comentam que, para classificação de imagens multi-espectral, a configuração mais utilizada é cada nó de entrada corresponde a cada banda da imagem, e cada nó de saída corresponder a cada classe desejada. O tamanho da camada oculta não é determinado.

Com relação ao número de nós na camada oculta, em Heermann e Khazenie (1992) foi determinado que é melhor começar com um número relativamente grande de nós na camada oculta. Conforme se façam novas experiências, pode-se diminuir o tamanho da camada oculta. A vantagem de se começar com um grande número de nós

na camada oculta é que o problema provavelmente será resolvido, embora lentamente. Quando se tem poucos nós, a aprendizagem pode oscilar, ou simplesmente não ocorrer.

O conjunto de treino tem ainda de ser suficientemente grande para ser representativo do problema (LEK e GUÉGAN, 1999). Chettri, Crompt e Birmingham (1992) afirmam que, de acordo com Richards (1986) uma amostra mínima de 60 pixels é necessária para uma classificação precisa. Além disso, o mesmo autor ainda relata que, conforme Campbell (1987), é melhor utilizar pixels bem distribuídos de vários lugares do que vários pixels de apenas um lugar.

3.2.3.2 *Support Vector Machine*

Segundo Ales (2008), o *Support Vector Machine* (SVM) é uma técnica de reconhecimento de padrões baseada na metodologia de aprendizagem e gera resultados robustos. Foi desenvolvido durante três décadas e passou por melhoramentos importantes. Inicialmente, a técnica classificava apenas pontos linearmente separáveis, classificando em classes com a máxima distância entre estas. Em virtude disso, a probabilidade de classificar um ponto incorretamente tornava-se mínima. Seu processo de aprendizagem é supervisionado, ou seja, os dados de treinamento, juntamente com suas respectivas saídas são apresentados à máquina para ajuste dos parâmetros.

Como descrito em Andreola e Haertel (2009), considerando x_i , com $i=1, 2, \dots, m$, um conjunto de treinamento de um problema que consiste de duas classes linearmente separáveis (ω_1 e ω_2), a cada x_i fica associado um valor correspondente: $y_i=1$ se x_i pertence a ω_1 , e $y_i=-1$ se x_i pertence a ω_2 .

O processo de treinamento consiste em treinar o classificador para que este aprenda o mapeamento (x,y) por meio destes exemplos de treinamento (x_i,y_i) , de forma que a máquina seja capaz de classificar outro elemento. Ou seja, quando apresentado um valor x , retorne o valor associado y (NASCIMENTO *et al.*, 2009).

A formulação do SVM pode ser encontrada em Foody e Mathur (2004), Kavzoglu e Colkesen (2009), Evgeniou e Pontil (2001), Alonso e Malpica (2008), Burges (1998). O método consiste, basicamente, em se identificar a fronteira de decisão

entre as classes em função dos dados de treinamento apresentados. Esta fronteira pode ser dada por:

$$g(x) = w^t x + b = 0$$

Onde w^t é o vetor transposto de pesos e b é o termo independente.

Os dados de treinamento então devem satisfazer as seguintes condições:

$$\begin{aligned} w^t x + b &\geq 1 && \text{para } y_i = 1 \\ w^t x + b &\leq -1 && \text{para } y_i = -1 \end{aligned}$$

Podendo ser combinadas na seguinte inequação, para todos os dados de treinamento:

$$y_i(w^t x + b) - 1 \geq 0$$

Estas condições e equações podem ser exemplificadas como na Figura 14.




Figura 14 - Representação do plano e margens obtidos no treinamento do SVM (KAVZOGLU e COLKESEN, 2009)

Entretanto, esta abordagem, segundo Andreola e Haertel (2009), apresenta o risco de excesso de ajuste (*overfitting*), o qual resulta em perda de generalização do classificador. Para tratar dos casos linearmente não-separáveis, pode-se introduzir uma variável de folga (*slack variable*) ξ_i .

Comumente, as classes não são linearmente separáveis, e as equações não podem ser satisfeitas. Para lidar com estes casos, utilizando apenas limites de separação

lineares, um novo conjunto de variáveis, por vezes referido como variáveis de folga (FOODY e MATHUR, 2004). Ales (2008) também afirma que, para aumentar a capacidade de generalização do SVM, acrescentam-se variáveis de folga ξ_i . Sendo obtidas durante o processo de treinamento do SVM.

Com isto, pode-se representar as equações como:

$$w \cdot x + b \geq 1 - \xi_i \quad \text{para } y_i = 1$$

$$w \cdot x + b \leq -1 + \xi_i \quad \text{para } y_i = -1$$

$$\text{com } \xi_i \geq 0.$$

Isto pode ser representado como indicado na Figura 15.




Figura 15 - Representação da variável de folga (KAVZOGLU e COLKESEN, 2009)

Quando não é possível definir o hiperplano pelas equações lineares, os dados podem ser mapeados em um espaço dimensional maior, através de algumas funções de mapeamento não linear.

Segundo Ales (2008), são raros os casos reais em que os conjuntos são linearmente separáveis. Pode-se então fazer um mapeamento dos dados não-lineares em um espaço de dimensão maior, onde os dados tornam-se linearmente separáveis. Como dito por Andreola e Haertel (2009), frequentemente, as duas classes não são linearmente separáveis, e a separação entre as amostras de treinamento das duas classes requer uma

função não-linear. A solução mais simples nestes casos consistiria na adoção de polinômios de grau mais elevado.

De acordo com Burges (1998), as funções de Kernel mais conhecidas, como a polinomial, radial e sigmoide, podem ser representadas, respectivamente, como:

$$K(x, y) = (x \cdot y + 1)^p$$

$$K(x, y) = e^{-|x-y|^2/2\sigma^2}$$

$$K(x, y) = \tanh(kx \cdot y - \delta)$$

A representação da elevação dos dados a um espaço de maior dimensão pelas funções de Kernel, pode ser representado como indicado na Figura 16.




Figura 16 - Mapeamento dos conjuntos de dados para o de maior dimensão com uma função Kernel (KAVZOGLU e COLKESEN, 2009).

E, por fim, Ales (2008) acrescenta dizendo que a junção de variáveis de folga e função *Kernel* possibilitaram a classificação de dados não separáveis linearmente. Os resultados do SVM, como técnica de reconhecimento de padrões, mostraram-se satisfatórios, obtidos nas mais variadas áreas.

3.2.4 Avaliação dos Métodos de Filtragem e Classificação

A escolha do melhor mapa temático foi baseada num estudo comparativo entre os resultados obtidos pelos diferentes Métodos de Filtragem dos dados *Laser Scanner* e Classificadores digitais de imagens.

Para a avaliação do desempenho dos algoritmos serão analisados os resultados com base na matriz de erros (ou matriz de confusão). Neste processo, é realizada a comparação entre a verdade terrestre e os resultados disponíveis na imagem temática. Para isto, novas áreas de verificação são escolhidas na imagem. A verdadeira classificação destas áreas deve ser conhecida com certeza, neste caso classificado pelo próprio autor. Ou seja, para confrontar os resultados obtidos pelos métodos de filtragem e classificação, o autor fez a filtragem de pontos que eram do terreno ou de objetos, assim como a classificação de árvores e não árvores.

A matriz de erros contém, nas suas células, o total de pixel corretamente classificados (na diagonal principal da matriz), bem como os erroneamente classificados dentro de uma classe diferente daquela esperada (valores fora da diagonal principal da matriz), sendo os erros de comissão e de omissão.

Erros de omissão são os pixels que o classificador errou em deixar de classificar determinado pixel na respectiva classe, classificando este pixel em outra classe. Erros de comissão são os pixels que não pertenciam a classe, mas que o classificador acabou por colocá-lo na classe, ou seja, pixels de outras classes que são classificados erroneamente como sendo desta determinada classe.

3.2.5 Simulação dos Caminhos do Escoamento Superficial

A fonte de dados de elevação do terreno neste projeto é o modelo digital obtido a partir da filtragem dos dados *Laser Scanner* e classificação e retirada de elementos como árvores e redes de transmissão de energia, sendo denominado Modelo Digital de Superfície Urbana (MDSu). A disponibilidade deste MDSu permite calcular e mapear os caminhos do escoamento ao longo da superfície do terreno, os quais podem também ser utilizados para a derivação de outras variáveis hidrológicas relevantes, como a declividade média do curso de água ou a rede de drenagem.

Os trabalhos de O'Callaghan e Mark (1984), Mark (1984) e Jenson e Domingue (1988) foram fundamentais para o desenvolvimento de métodos de estimativa da direção de escoamento nas células de uma grade altimétrica. Estes estudos, inicialmente, eram aplicados utilizando modelos derivados da digitalização de mapas topográficos e mais recentemente de modelos de sensoriamento remoto, como aqueles obtidos pelo sistema *Shuttle Radar Topography Mission* (SRTM). Ao longo dos anos, esta técnica foi aprimorada, como será apresentado a seguir. Porém pouco foi pesquisado no caso do uso de modelos de terreno altamente detalhados, como são os disponíveis atualmente através da tecnologia *Laser Scanner*.

Neste sentido, o seguinte passo é a comparação de diferentes métodos de estimativa de direções de escoamento a partir do modelo digital do terreno. Os métodos considerados são explicados nas subseções seguintes.

3.2.5.1 D8

Tarboton (1997) relata que é o método mais antigo e mais simples de especificar direções do fluxo, sendo introduzido por O'Callaghan e Mark (1984) e têm sido amplamente utilizado.

De acordo com Crombez (2008); Wilson *et al* (2008); Tarboton, (1997); Erskine *et al* (2006); e Júnior, (2009); o algoritmo D8 (*deterministic eight neighbours*) é o método mais comum de fluxo em caminho único, consistindo na atribuição de todo o fluxo de uma célula central para um de seus oito vizinhos, vizinho este escolhido por proporcionar maior declividade.

Basicamente, o método funciona da seguinte maneira:

- Inicialmente, todas as depressões do modelo são preenchidas;
- A seguir, é calculada a declividade entre o pixel central de uma janela móvel e seus oito vizinhos imediatos;
- O vizinho associado à maior declividade é escolhido e a direção do fluxo aponta para este vizinho
- Caso existam mais de um pixel com a menor declividade, apenas um deles é selecionado.

O cálculo para determinar os caminhos do escoamento é simples, e Crombez (2008) afirma que este modelo é o mais popular entre os softwares de SIG, por ser computacionalmente eficiente. Erskine *et al* (2006) critica dizendo que este método é computacionalmente eficiente, mas produz caminhos de fluxo irrealistas, retos e paralelos. Porém, o cálculo para determinar a área contribuinte a montante é simples e pode ser realizado rapidamente.

No entanto, o algoritmo não funciona bem para áreas divergentes, ou planas. No último caso, o fluxo é muito simplificado, representando redes de drenagem paralelas. Este modelo atua efetivamente na geração de aproximações grosseiras, sendo recomendado apenas para quando esses valores exatos não são essenciais, ou em fases de pré-planejamento de um projeto (CROMBEZ, 2008)

Conforme relatado em Paz e Collischonn (2008), diversas modificações do algoritmo D8 e algoritmos alternativos de geração de direções de fluxo têm sido propostos. Principalmente, visando diminuir o custo computacional e melhorar os resultados do tratamento de áreas planas. Por exemplo, o algoritmo original D8 tende a gerar linhas paralelas irreais na drenagem, as quais podem ser quase completamente evitadas pela introdução de um fator aleatório no tratamento de áreas planas introduzidas por Fairfield e Leymarie (1991).

Tarboton (1997) ressalta que a abordagem D8 tem desvantagens resultantes justamente da discretização do fluxo para apenas uma das oito direções possíveis, separadas por 45°. O mesmo autor ainda argumenta que Fairfield e Leymarie (1991), para melhorar esta condição, sugeriram introduzir um fator aleatório para a direção do fluxo, com uma probabilidade proporcional ao declive.

3.2.5.2 Rh8

Segundo Wilson *et al* (2008), o algoritmo Rh8, desenvolvido por Fairfield e Leymarie (1991), introduziu um grau de aleatoriedade para quebrar os caminhos de fluxo paralelos que o D8 tende a produzir em superfícies planas. Este algoritmo é iniciado identificando todas as células vizinhas de menor elevação, calculando os gradientes para cada uma dessas direções. Os números aleatórios são alocados em uma

base ponderada em função da inclinação, tal que os caminhos de fluxo potenciais, de maior gradiente, tenham a maior probabilidade de serem selecionados.

No entanto, é de difícil reprodução, pois a cada vez que o algoritmo é executado, mesmo que seja sobre a mesma área, pode gerar resultados distintos em função desta aleatoriedade, a qual não é atraente. Isto porque as áreas contribuinte são determinísticas, devendo ser capaz de se calcular de forma repetível (TARBOTON, 1997).

3.2.5.3 MS

Na tentativa de minimizar ou solucionar os problemas originados no método D8, pesquisadores propuseram o método MS (*Multiple Directions based on Slope*) (QUINN *et al.*, 1991), que aloca uma fração do fluxo para cada vizinho de igual ou menor elevação em relação ao declive do terreno. Notou-se também que uma desvantagem desse método é que o fluxo de um único pixel pode se espalhar para todos os seus vizinhos com menor elevação.

Diferentemente dos algoritmos de direção única, os métodos de direções múltiplas admitem que o escoamento de uma célula possa se dirigir para mais de uma das oito células vizinhas. A abordagem de direções múltiplas surgiu com o intuito de minimizar o que era tido como uma limitação do método D8. A consideração de direção única adotada nos métodos D8 é, a rigor, uma simplificação da situação real, já que o fluxo gerado em uma determinada célula realmente não segue concentrado para apenas uma das oito células vizinhas (BUARQUE *et al.*, 2009).

Contudo, de acordo com Jones (2002) apud Buarque *et al* (2009) para a definição de rede e áreas de drenagem, a adoção de direções múltiplas não é adequada, pois pode-se ter a geração de limites difusos e sobrepostos de áreas de contribuição.

3.2.5.4 FRh8

Segundo Crombez (2008), o modelo FRh8 é mais sofisticado que o D8 e o Rh8. Este modelo pode reconhecer explicitamente que o fluxo de encostas devem ser divergentes enquanto o fluxo ao longo de fundo de vale deve ser convergente.

O algoritmo FRh8 incorpora o elemento aleatório do Rh8 ao método de múltiplos fluxos. Nele, o fluxo é dirigido aos vizinhos com proporção aleatória do fluxo, em vez de estar diretamente relacionada com a diferença de elevação. Sendo assim, gera as mesmas preocupações que o Rh8, por gerar resultados que não podem ser repetidos.

3.2.5.5 Dinfinito

Este algoritmo reconhece as vantagens dos métodos de Lea e DEMON, através da atribuição de um sentido único de fluxo para cada célula. Esta direção, representada como um vetor variando o ângulo entre 0 e 2π , é determinada no sentido de declividade mais íngreme, sobre oito facetas triangulares formadas numa janela 3x3 centrada no pixel de interesse (TARBOTON, 1997).

Conforme Erskine *et al* (2006), a direção do fluxo é dada para a descida mais acentuada das oito facetas triangulares formadas numa janela de 3x3 elementos. O fluxo é então dividido para os dois vizinhos que formam esta faceta com base no vetor resultante.




Figura 17 - Oito facetas triangulares planas são formadas entre o pixel e os seus oito vizinhos (adaptado de TARBOTON, 1997).

Na Figura 17 a direção do fluxo é definida por um ângulo da faceta com menor valor de declividade. Os valores 1; 2; 3,..., 8 representam as facetas triangulares definidas para o cálculo da direção entre o pixel central e seus oito vizinhos, o cálculo do valor da proporção de fluxo do ponto central representado pela posição (i; j) para o vizinho de posição (i-1; j) é representado pela equação $\alpha_2/(\alpha_1 + \alpha_2)$ que determina a quantidade de fluxo que escoará naquela direção, pode-se notar que o fluxo maior escoará para o pixel de posição (i-1; j+1) representado pela equação $\alpha_1/(\alpha_1 + \alpha_2)$ (JÚNIOR, 2009).




Figura 18 - Cálculo da declividade do método Dinfinito (TARBOTON, 1997).

A Figura 18 faz uma análise da faceta de número 1, mostrada na Figura 17, que tem como pontos analisados os pixels e_0 de posição (i; j), o pixel e_1 de posição (i; j+1) e

o pixel e_2 de posição $(i-1; j+1)$, e a distância entre estes pontos definidos por d_1 e d_2 . A distância entre o pixel analisado e seus dois vizinhos que formam a faceta para análise depende exclusivamente da resolução espacial do MDT (JÚNIOR, 2009).

Segundo Tarboton (1997), com base na avaliação das estatísticas de testes e análise dos mapas de influência gerados, o Dinfinito apresenta resultados melhores que D8 e MS. Ainda, Erskine *et al* (2006) concluiu que Dinfinito é computacionalmente mais eficiente que o DEMON.

3.2.6 Avaliação dos Resultados da Simulação do Escoamento Superficial

Até recentemente, a estimativa dos caminhos do escoamento na superfície se restringia a modelos digitais grosseiros, em escalas menores, em função dos dados disponíveis. Alguns trabalhos, como Buarque *et al.*(2009), se preocuparam em analisar os diferentes métodos de estimativa dos caminhos do escoamento em grades de resolução grosseira. Hoje, com a disponibilidade de alto grau de detalhe oferecida pelo *Laser Scanner*, este estudo deve ser estendido às grades de alta resolução. Por isso, na primeira parte da avaliação, os métodos de estimativa de caminhos de água serão avaliados e comparados.

A abordagem tradicional é utilizar o método de estimativa dos caminhos de água para gerar uma rede de drenagem e compará-la com uma rede de referência, obtida, por exemplo, de um mapa em escala compatível ou de imagens de satélite. Isto se torna inviável em se tratando de dados de alta resolução, pois neste caso não existe um mapa de escoamento superficial de referência.

A primeira avaliação foi visual, tentando identificar erros grosseiros, como a formação de canais paralelos em áreas onde se espera concentração do fluxo, ou a formação de concentrações em rampas. Embora não se conte com um detalhe da rede de drenagem real, existem fatos que podem ser verificados, decorrentes da geometria das ruas asfaltadas. Por exemplo, em ruas asfaltadas o escoamento é direcionado às bordas, com a finalidade de ser coletado pelas bocas de lobo localizadas nas proximidades das calçadas.

Dos passos anteriores foram obtidas diferentes grades representando o terreno. A base conceitual de cada método de filtragem origina diferenças no modelo do terreno obtido, que podem influenciar o escoamento superficial, alterando os caminhos do escoamento em função de diferenças altimétricas, por exemplo depressões, introduzidas no processo de filtragem. Por isto, foi feita a análise comparativa dos métodos de filtragem. Para a escolha do método mais adequado, a rede de drenagem de todos os modelos obtidos serão estudadas e analisadas, detectando incoerências na rede em função de falhas da interpolação ou remoção de pontos.

Infelizmente, não foi possível o mapeamento em campo do fluxo do escoamento superficial nas áreas de estudo para comparação dos resultados dos algoritmos. Entretanto, como forma de quantificar os resultados obtidos, foi feita a verificação do comprimento do escoamento gerado com o tamanho de duas vias no Centro Politécnico. Nestas ruas, devido ao seu formato e inclinação, sabe-se que o escoamento deve ser próximo ao comprimento das mesmas. Ou seja, devido à configuração dessas ruas, os escoamentos não devem ser tortuosos ou gerar quebras e meandros, devem ter comprimentos similares com os das vias.

4 Resultados e Discussões

Nas seções a seguir são apresentados alguns resultados, de acordo com cada etapa da metodologia. Os demais resultados que, por ventura, não são apresentados na respectiva seção, estão presentes nos apêndices.

4.1 Pré-tratamento dos dados

4.1.1 Centro Politécnico – UFPR

Os dados *Laser Scanner* necessitam de um tratamento prévio, uma vez que, quando agrupados em formato *raster*, ou grade, podem existir pixels que acabam por ficar sem valores correspondentes. A Figura 19 apresenta os dados de altimetria do *Laser Scanner* organizados no formato *raster*, sem este tratamento prévio.

Percebe-se que vários pixels encontram-se sem informação, representados por pixels escuros, dentro da faixa de dados. Isto foi corrigido através de morfologia matemática, como descrito anteriormente (seção 3.2.1, pag. 58). Após utilizar as operações de dilatação seguida de erosão, combinação esta que também é conhecida como fechamento, obteve-se a Figura 20.

Percebe-se que a imagem foi suavizada, preenchendo a grande maioria dos pixels que estavam sem informação, restando apenas alguns, normalmente que se encontram atrás de grandes estruturas, como prédios, caracterizando regiões de oclusão, ou sombra. Ainda, antes de verificar estas regiões de sombra, foi aplicado novamente operações de morfologia matemática sobre esta imagem, desta vez a operação e abertura, que se trata de erosão seguida de dilatação. Isto para que dados de ruído fossem filtrados, assim como pequenas feições, como linhas de transmissão de energia. A Figura 21 apresenta estes dados após esta operação de abertura.




Figura 19 – Dados de altimetria do *Laser Scanner* do Campus Centro Politécnico, organizados em formato *raster*, sem tratamento prévio.




Figura 20 – Dados de altimetria do *Laser Scanner* do Campus Centro Politécnico, após operação de fechamento.




Figura 21 – Dados de altimetria do *Laser Scanner* do Campus Centro Politécnico, após operação de fechamento, seguida da operação de abertura.

As alterações depois do processo de abertura podem ser de difícil visualização. Entretanto, é possível verificar que a imagem se encontra em uma tonalidade mais nítida, onde a escala é ajustada, uma vez que esta passou de ter um limite superior de 50 metros para aproximadamente 45 metros. A alteração da escala se deu em função da retirada de informações de ruído, que, neste caso, representavam pontos muito acima do terreno.

Por fim, são verificadas as regiões de oclusão, ou sombra, formadas por feições muito altas, como edificações. Após a detecção destas regiões, obtêm-se a imagem apresentada na Figura 22, onde todos os pixels presentes na faixa de dados possuem valores, com a preservação de grande parte dos dados originais e uma boa representação da realidade. Esta imagem final possui um total de 596.785 pixels com informação altimétrica e multiespectral

O Modelo Digital de Superfície obtido a partir destes dados *Laser Scanner* desta área em estudo é mostrado na Figura 23.




Figura 22 – Dados de altimetria do *Laser Scanner* do Campus Centro Politécnico, após verificação de pixels sem informação.




Figura 23 – Modelos Digital de Superfície em 3 dimensões, gerados a partir dos dados de altimetria do *Laser Scanner*, do Campus Centro Politécnico.

4.1.2 Água Verde / Rebouças

Para a área da Água Verde / Rebouças foi feito o mesmo procedimento, onde os dados foram organizados em formato *raster*, também gerando pixels sem informação, como mostrado na Figura 24.

Novamente, foram aplicados os operadores morfológicos de dilatação e erosão, o fechamento, para preenchimento da maioria dos pixels sem informação. O resultado pode ser visto na Figura 25. A suavização da imagem foi perceptível, onde a grande maioria dos pixels possui informação, possibilitando maior discriminação das feições na imagem, restando apenas poucos pixels sem informação.

Foi aplicada também a operação morfológica de abertura, para retirada de ruídos e pequenas feições. Novamente, a visualização das alterações é difícil, porém pode-se perceber que o valor máximo da escala da Figura 26 também sofreu redução, melhorando a distribuição da escala da legenda, tornando a imagem mais nítida. A Figura 27 traz um recorte da imagem para percepção da remoção de feições como redes de transmissão de energia, após esta operação de abertura, sem alterar as demais feições.

Por fim, foram verificados os pixels sem informação, ou possíveis regiões de oclusão ou sombra. O resultado final obtido é apresentado na Figura 28.

O Modelo Digital de Superfície desta área de estudo, gerado a partir destes dados *Laser Scanner*, é mostrado na Figura 29, em dois ângulos de visualização. É possível verificar claramente feições como edificações, assim como variações no terreno irregular.




Figura 24 – Dados de altimetria do *Laser Scanner* de parte do bairro Água Verde / Rebouças, organizados em formato *raster*, sem tratamento prévio.




Figura 25 – Dados de altimetria do *Laser Scanner* de parte do bairro Água Verde / Rebouças, após operação de fechamento.




Figura 26 – Dados de altimetria do *Laser Scanner* de parte do bairro Água Verde / Rebouças, após operação de fechamento, seguida da operação de abertura.




Figura 27 – Detalhe da remoção de feições como redes de transmissão de energia após a operação de abertura.




Figura 28 – Dados de altimetria do *Laser Scanner* de parte do bairro Água Verde / Rebouças, após verificação de pixels sem informação.

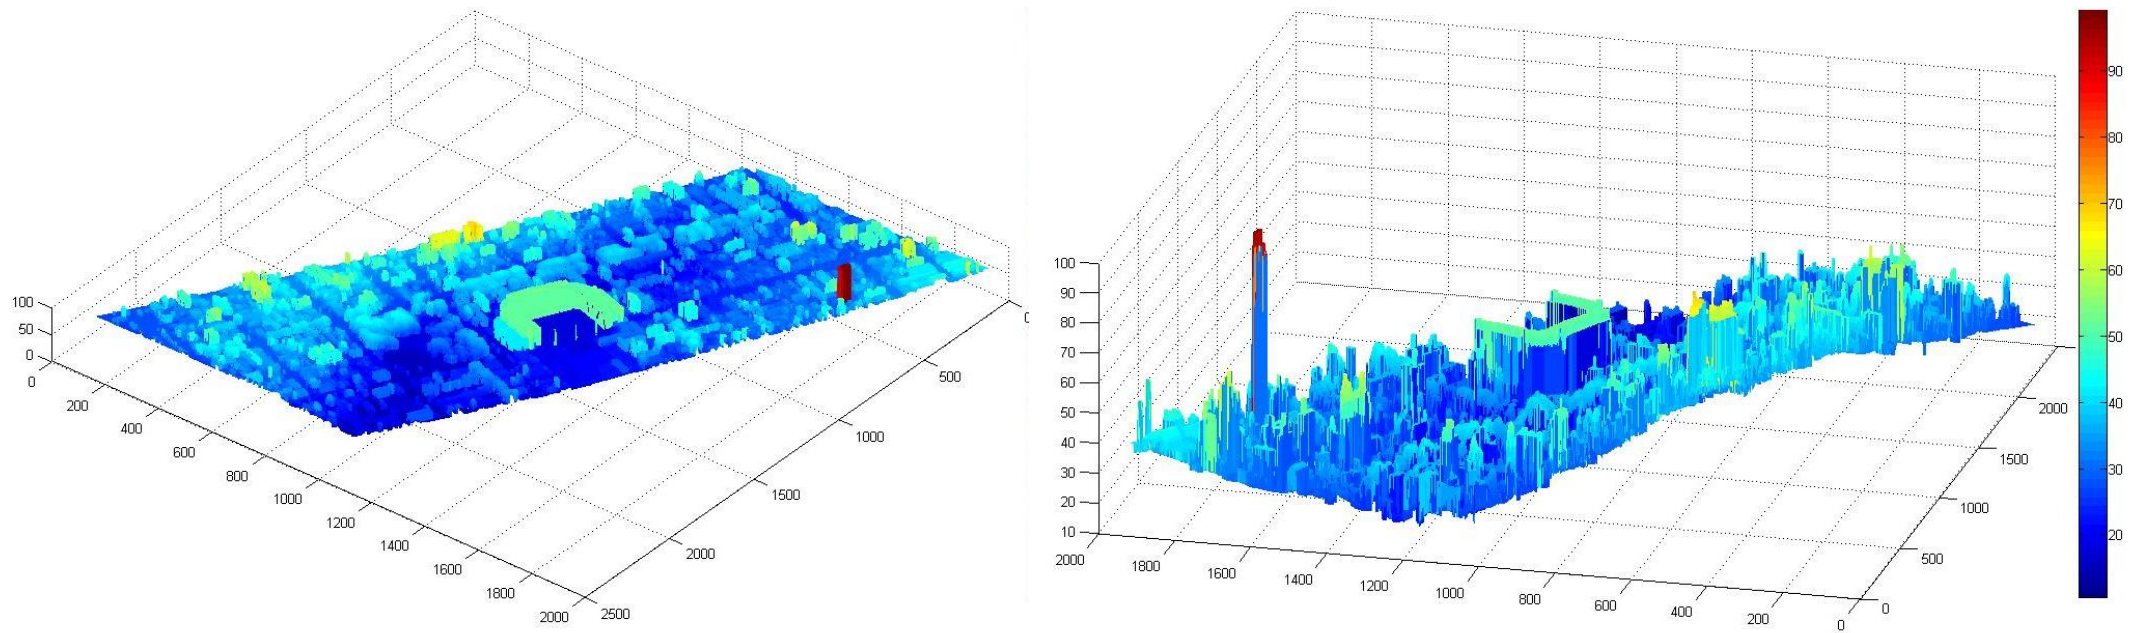


Figura 29 - Modelo Digital de Superfície em 3 dimensões gerado a partir dos dados de altimetria do *Laser Scanner* de parte dos bairros Água Verde / Rebouças – Curitiba
–PR – BR.

Porém, como os dados *Laser Scanner* disponíveis são apenas para uma faixa de dados, e em tamanho e resolução diferentes da imagem espectral disponível, a imagem espectral teve que ser recortada e reduzida a resolução espacial, de 0,30 metros para 0,50 metros, como os dados *Laser Scanner*. Os dados que foram utilizados neste trabalho são a informação do *Laser Scanner* e imagem espectral, com o mesmo tamanho e resolução espacial, apresentados na Figura 30. Esta imagem possui 3.552.840 pixels, mas apenas 1.904.357 pixels possuem informações altimétricas e espectrais, presentes na faixa de dados.




Figura 30 – Faixa de dados com informação espectral e de *Laser Scanner* para parte do bairro Água Verde / Rebouças.

4.2 Métodos de Filtragem

As imagens filtradas pelo autor, consideradas as verdades de campo, para posterior avaliação dos resultados dos Métodos de Filtragem, são apresentadas nas Figura 31 e Figura 32.




Figura 31 – Filtragem dos Dados *Laser Scanner* para a Área do Centro Politécnico.




Figura 32 - – Filtragem dos Dados *Laser Scanner* para a Área da Água Verde / Rebouças.

A fim de quantificar os resultados, foram comparados através de matrizes de confusão os resultados dos métodos de filtragem com as Figura 31 e Figura 32 -

consideradas como verdades de campo. Como exemplo dessas matrizes, são apresentadas as Tabela 4 e Tabela 5. As demais matrizes de confusão, para a Área do Centro Politécnico e Água Verde / Rebouças, nos APÊNDICE B (pág. 129) e APÊNDICE E (pág. 135), respectivamente.

Tabela 4 - Matriz de Confusão para o Método de Filtragem ETEW, para a Área do Centro Politécnico.

Classes	Terreno	Não Terreno	
Terreno	339.874	39.197	89,66%
Não Terreno	38.975	178.739	82,10%
	89,71%	82,01%	86,90%

Tabela 5 – Matriz de Confusão para o Método de Filtragem de Morfologia Matemática, com operador quadrado, para a Área da Água Verde / Rebouças.

Classes	Terreno	Não Terreno	
Terreno	774.974	58.970	92,93%
Não Terreno	128.308	942.060	88,01%
	85,80%	94,11%	90,17%

Nestas matrizes de confusão estão representados os valores de acertos e erros ao se confrontar os resultados dos Métodos de Filtragem com a filtragem feita pelo autor. Os valores apresentados são referentes aos pixels classificados como terreno ou pixels de objetos, que não são terreno. O ideal seria ter valores apenas na diagonal principal, ou seja, os pixels classificados pelo autor como terreno ou não terreno, também teriam a mesma classificação como resultado dos métodos de filtragem. Os valores fora desta diagonal principal representam classificações errôneas. Os valores percentuais representam a porcentagem de acertos, com atenção especial ao valor percentual do canto inferior direito, que representa o acerto global, obtido através do somatório da diagonal principal sobre o valor total de pixels.

No caso da Tabela 4, 339.874 pixels foram classificados como terreno e 178.739 como não terrenos tanto pelo autor como pelo método de filtragem ETEW. Ainda, 38.975 pixels foram classificados como terreno pelo método e não terreno pelo autor, e

39.197 como não terreno pelo classificador e terreno pelo autor. O acerto global deste método para a área do centro politécnico foi de 86,90%.

Como representado na Tabela 5, 774.974 pixels foram classificados como terreno e 942.060 como não terreno, tanto pelo autor como pelo método de Morfologia Matemática. 128.308 pixels foram classificados pelo método como terreno e não terreno pelo autor, e 58.970 pixels como não terreno pelo classificador e terreno para o autor. O acerto global deste método foi de 90,17%, o maior dentre todos os Métodos de Filtragem.

Algumas imagens dos resultados dos métodos de filtragem dos dados *Laser Scanner* são apresentados a seguir a fim de ilustrar certas características apresentadas neste processo de filtragem. As imagens geradas destes e dos demais resultados dos métodos de filtragem são apresentadas nos APÊNDICE A (pág.127) e APÊNDICE D (pág. 133), para a área do Centro Politécnico e Água Verde / Rebouças, respectivamente.

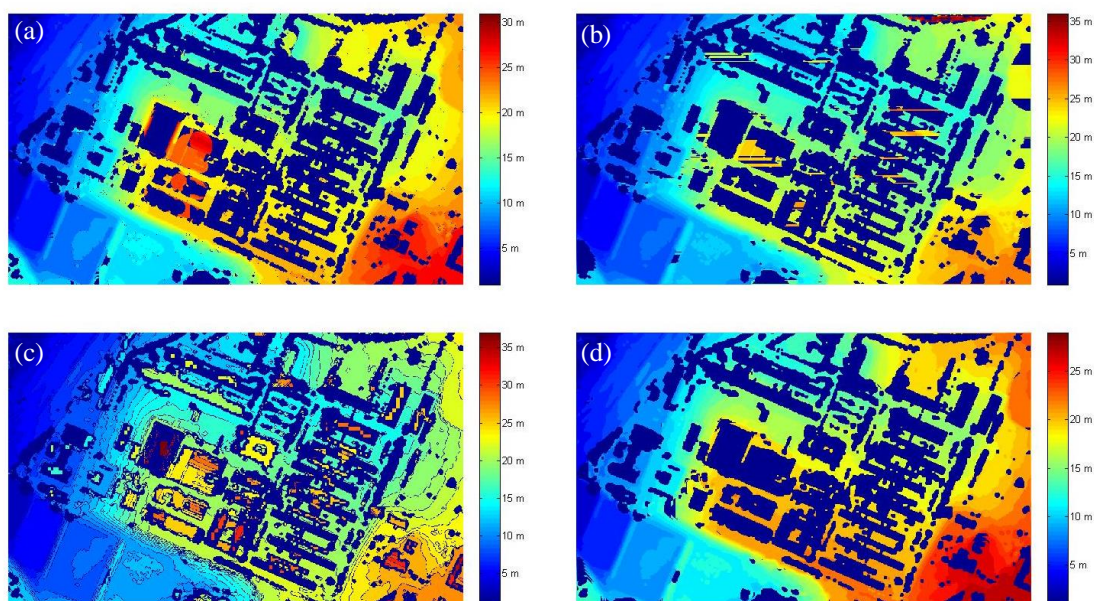


Figura 33 – Resultados dos Métodos de Filtragem para a área do Centro Politécnico (a) Morfologia Matemática ALDPAT, operador circular; (b) Morfologia Matemática, operador linear; (c) ETEW ALDPAT; (d) Morfologia Matemática, operador quadrado.

Como pode ser visto na Figura 33, cada método apresenta um resultado diferente, obtendo diferentes erros de omissão e comissão, ou seja, dados que deveriam

ser filtrados e não foram, ou dados que eram do terreno e não deveriam ter sido filtrados, mas foram.

Ao se comparar a Figura 33 (a), utilizando o método de filtragem de morfologia matemática com operador circular, e Figura 33 (b), com o mesmo método mas com operador linear, é possível verificar a influência do operador utilizado na filtragem. Como pode ser verificado, na Figura 33 (a), existem algumas feições circulares, na região central da imagem, onde, na verdade, é um prédio que deveria ter sido filtrado. Já na Figura 33 (b), nota-se algumas características lineares e, em sua totalidade, essas linhas são horizontais, em função do operador utilizado na filtragem. A Figura 33 (c) apresenta o resultado da filtragem utilizando o método ETEW do software ALDPAT. Nesta imagem é possível verificar que a filtragem não foi tão bem sucedida, uma vez que regiões do centro de alguns prédios não foram filtradas, caracterizando maiores erros de omissão. Ainda na mesma imagem, é possível verificar que no terreno, alguns pixels foram retirados, caracterizando também erros de comissão, ou seja, pontos que deveriam ser considerados do terreno e mantidos, mas foram retirados por ser considerados de objetos sobre o terreno. Por fim, pode-se comparar a Figura 33 (d) com as demais. Este resultado foi considerado o melhor, pois é possível verificar, mesmo visualmente, que os objetos acima do terreno foram filtrados significativamente, enquanto que o terreno foi preservado quase em sua totalidade. Sendo este resultado, obtido com morfologia matemática com operador quadrado, considerado o melhor dentre os resultados dos métodos de filtragem para a área do Centro Politécnico. Os demais resultados dos métodos de filtragem para a área do Centro Politécnico podem ser visualizados no APÊNDICE A (pág.127).

A Figura 34 traz a imagem do resultado que apresentou maior acerto global (90,17%) dentre todos os resultados dos demais Métodos de Filtragem, para a Área da Água Verde / Rebouças. Este resultado foi obtido pela utilização do Método de Filtragem de Morfologia Matemática com operador quadrado. Apesar de, mesmo visualmente ser possível verificar erros de comissão e omissão, como no caso da ausência de informação em parte do gramado do campo de futebol, este método foi considerado o melhor com base na comparação com os resultados dos outros métodos. Esta e outras imagens dos resultados, obtidos pelos métodos de filtragem, para a área da Água Verde / Rebouças, podem ser analisados no APÊNDICE D (pág. 133).




Figura 34 – Resultado do Método de Filtragem de Morfologia Matemática, operador quadrado, para a Área da Água Verde / Rebouças.

Os métodos de filtragem dos dados *Laser Scanner* utilizados neste trabalho apresentaram bons resultados. Contudo, em menor ou maior grau, todos contêm erros de omissão e comissão. Os maiores erros de omissão foram encontrados em feições como prédios largos, onde alguns pixels mais ao centro dos prédios foram conservados.

Os métodos de filtragem utilizando o software ALDPAT produziram resultados bons, considerando se tratar de um programa genérico para qualquer tipo de dados *Laser Scanner*, por mais que os métodos deste software apresentaram maiores erros. Entretanto, cada um desses métodos no software ALDPAT possui determinado número de parâmetros, o que levou a várias tentativas até encontrar os valores apropriados para cada área e análise.

Os métodos implementados em MATLAB apresentaram resultados melhores, mas necessitam da habilidade de programação do usuário, uma vez que os códigos tem que ser escritos pelo mesmo, não estando implementados como no software ALDPAT. Apesar da demanda da programação, os métodos implementados em MATLAB foram

desenvolvidos de maneira a não necessitar de tantos parâmetros, sendo a filtragem dos dados feita de maneira quase autônoma.

O método que apresentou melhores resultados dentre todos os utilizados foi o de morfologia matemática, mais especificamente, de operador quadrado ou circular, implementado em MATLAB. Entretanto, o método de morfologia matemática do software ALDPAT também obteve bons resultados, sendo uma boa alternativa, uma vez que já está implementado e necessita de menor quantidade de parâmetros e é de mais fácil compreensão, se comparado aos outros métodos do ALDPAT.

Após a filtragem dos dados *Laser Scanner*, os mesmos foram interpolados para preenchimentos dos espaços vazios gerados. Foi utilizado o método de interpolação bilinear. Com esses dados já interpolados, foi feito o processo de subtração dos dados originais *Laser Scanner* em formato *raster* com estes dados, ou seja, MDS – MDT, gerando o Modelo Digital de Superfície Normalizado (MDSn). A Figura 35 e Figura 36 trazem os MDSn, utilizando morfologia matemática, com operador circular e quadrado, das áreas do Centro Politécnico e Água Verde / Rebouças, respectivamente. Nelas, é possível verificar que a variação do terreno foi minimizada, uma vez que não há variação altimétrica, sendo que a variação é perceptível apenas nos objetos sobre o terreno. Os MDSn gerados, para cada método de filtragem, são apresentados no APÊNDICE C (pág. 131) para a área do Centro Politécnico e no e APÊNDICE F (pág. 137) para a área da Água Verde / Rebouças.




Figura 35 – Modelo Digital de Superfície Normalizado, utilizando o método de filtragem de morfologia matemática, operador circular, da área do Centro Politécnico.




Figura 36 – Modelo Digital de Superfície Normalizado, utilizando o método de filtragem de morfologia matemática, operador quadrado, da área da Água Verde / Rebouças.

4.3 Classificação Digital de Imagens

As informações espectrais, de intensidade de retorno do *Laser Scanner*, e os dados altimétricos dos MDSn - apresentados nos APÊNDICE C (pág. 131) e APÊNDICE F (pág. 137) - foram então utilizados no processo de treinamento dos classificadores RNA e SVM, assim como na classificação dos pixels relativos às árvores por esses classificadores.

Ainda, como já dito anteriormente na seção 3.2.3, pág. 64, os treinamentos foram executados com tamanhos diferentes de amostras, sendo 5%, 10%, 15%, 20%, 25%, 30%, 35%, 40%, 45% e 50% das amostras classificadas pelo autor. Os outros 50% foram utilizadas para validação dos resultados obtidos.

Após o pré-tratamento das imagens, tem-se o valor total dos pixels das imagens que poderão ser utilizados. Com isso, transformando essas porcentagens relativas, referentes à classificação pelo autor, em porcentagens absolutas, em relação ao número total de pixels com informação altimétrica e espectral das imagens, tem-se:

- No caso da área do Centro Politécnico, como a imagem possui 596.785 pixels com informação altimétrica e multiespectral, e foram classificados pelo autor 377.656 pixels (63,28% da imagem), o treinamento dos classificadores se deu com 3,16%, 6,33%, 9,49%, 12,66%, 15,82%, 18,98%, 22,15%, 25,31%, 28,48%, 31,64% do total de pixels da imagem, e outros 31,64% dos pixels para validação dos resultados.
- Para a área da Água Verde / Rebouças, como existem 1.904.357 pixels com informação altimétrica e espectral, e foram classificados pelo autor 579.518 pixels (30,43% destes pixels com informação), o treinamento se deu com 1,52% 3,04% 4,56% 6,09% 7,61% 9,13% 10,65% 12,17% 13,69% 15,22% da imagem, e com a utilização de outros 15,22% da imagem para validação dos resultados obtidos pelos classificadores.

Novamente, para melhor entendimento, estes dados foram organizados, como anteriormente apresentado na Tabela 3, pag. 65, porém, acrescida das porcentagens relativas a cada imagem, tendo assim a Tabela 6.

Tabela 6 - Quantidade de pixels amostrados, com percentuais em relação à amostragem e às imagens, para as áreas de estudo.

	Centro Politécnico			Água Verde / Rebouças		
	Quantidade	Percentual em relação ao Amostrado	Percentual em relação à Imagem	Quantidade	Percentual em relação ao Amostrado	Percentual em relação à Imagem
Valor total amostrado	377.656	100%	63,28%	579.518	100%	30,43%
Conjuntos de Treinamento	18.882	5%	3,16%	28.975	5%	1,52%
	37.765	10%	6,33%	57.951	10%	3,04%
	56.648	15%	9,49%	86.927	15%	4,56%
	75.531	20%	12,65%	115.903	20%	6,09%
	94.414	25%	15,82%	144.879	25%	7,61%
	113.296	30%	18,98%	173.855	30%	9,13%
	132.179	35%	22,15%	202.831	35%	10,65%
	151.062	40%	25,31%	231.807	40%	12,17%
	169.945	45%	28,48%	260.783	45%	13,69%
	188.828	50%	31,64%	289.759	50%	15,22%
Validação	188.828	50%	31,64%	289.759	50%	15,22%

Os resultados obtidos pelos classificadores RNA e SVM são apresentados e discutidos nas seções 4.3.1 e 4.3.2.

4.3.1 Redes Neurais Artificiais

A seguir são apresentados os resultados obtidos pela classificação dos pixels correspondentes às árvores, na área do Centro Politécnico e da área da Água Verde / Rebouças, pelo classificador RNA.

Para validação, foram geradas matrizes de confusão, onde as linhas representam as classes classificados pelo autor, e as colunas são as classes classificados pelo classificador. Seria interessante que todos os valores se encontrassem na diagonal principal desta matriz, representando que todos os pixels foram classificados assertivamente pelo classificador em relação ao autor. A porcentagem apresentada no canto inferior direito representa o acerto global do classificador, enquanto que os acertos parciais são apresentados nas porcentagens da linha e coluna final da matriz. A Tabela 7 apresenta uma matriz de confusão gerada pela classificação com RNA, utilizando 10% de amostra de treinamento, e informação altimétrica do MDSn obtido

pelo método de filtragem dos dados *Laser Scanner* de morfologia matemática, com operador circular, do software ALDPAT, para a área do Centro Politécnico.

Tabela 7 – Matriz de confusão – classificador RNA, com 10% de amostra de treinamento, MDSn a partir do método de Filtragem de morfologia matemática, com operador circular, do software ALDPAT, para a área do Centro Politécnico.

Classes	Árvores	Não Árvores	
Árvores	154.682	1.326	99,15%
Não Árvores	564	32.256	98,28%
	99,64%	96,05%	99,00%

Como pode ser visto na matriz de confusão, apresentada na Tabela 7, 154.682 pixels foram classificadas pelo autor e pelo classificador como sendo da classe árvores, e 32.256 como pixels que não representavam árvores, podendo ser construções ou gramados. Entretanto, houve divergência na classificação de 564 pixels, que o autor considera como não árvores e o classificador como árvore, e 1.326 pixels que o classificador considera como não árvores e o autor como árvores. O acerto global, apresentado no canto inferior direito, que é obtido em função do número total de acertos sobre o número total de pixels classificados (soma da diagonal principal dividida pela soma total da matriz), foi de 99,00%. Ou seja, para este caso, o classificador acertou 99,00% dos pixels em relação à classificação feita pelo autor.

Tabela 8 – Matriz de confusão – classificador RNA, com 50% de amostra de treinamento, MDSn a partir do método de Filtragem de morfologia matemática, com operador quadrado, para a área da Água Verde / Rebouças.

Classes	Árvores	Não Árvores	
Árvores	212.608	3.849	98,22%
Não Árvores	1.718	71.584	97,66%
	99,20%	94,90%	98,08%

A matriz de confusão, apresentada na Tabela 8, traz valores distintos, sendo que 212.608 pixels foram classificados pelo autor e classificador como sendo árvores na área da Água Verde / Rebouças, e 71.584 como sendo não árvores. 1.718 pixels foram considerados árvores pelo classificador e não árvores pelo autor, e 3.849 como árvores pelo autor e não árvores pelo classificador. Isto representa um acerto global de 98,08%.

As demais matrizes de confusão, em função o método de filtragem e a porcentagem utilizada no treinamento do classificador podem ser encontradas nos APÊNDICE G (pág. 139) e APÊNDICE H (pág. 150), para a área do Centro Politécnico e Água Verde / Rebouças, respectivamente.

Com os acertos globais de cada matriz de confusão gerada, foram construídas as Tabela 9 e Tabela 10, e Figura 37 e Figura 38.

Como pode ser visto nas Tabela 9 e Tabela 10, e Figura 37 e Figura 38, os acertos globais apresentam valores muito altos, com o menor valor de 86,63% para o método de filtragem de formação de pirâmide, com 10% de amostras de treinamento, e maior valor de 99,04% para o método de filtragem com morfologia matemática, com operador circular, do software ALDPAT. Sendo que a grande maioria dos acertos globais se encontra acima de 97%.

A Figura 37 e Figura 38 foram criadas de forma que fosse possível identificar um crescimento nos acertos globais conforme se aumentasse o número de amostras de treinamento, uma vez que é de se esperar que aumentando a amostra de treinamento, aumente-se a capacidade de discriminação de pequenas variações em valores. Entretanto, é possível verificar que há sim uma tendência de crescimento dos acertos, mas não necessariamente linear e constante com o aumento das amostras de treinamento. Esta tendência de crescimento dos acertos fica um pouco mais evidente na Figura 38 (b), que é para a área da Água Verde / Rebouças, sem a informação do método da formação de pirâmide, que obteve resultados piores na classificação e dificultou a visualização desta variação na Figura 38(a).

O que se pode concluir desta análise, é que os resultados obtidos foram muito bons, com valores altos de acertos globais para o classificador RNA, com diferentes tamanhos de amostras de treinamento e dados MDSn obtidos por diferentes métodos de filtragem de dados *Laser Scanner*. Sendo assim, é possível destacar que menores quantidades de amostras de treinamento produzem resultados tão bons quantos de grandes amostras de treinamento.

Além disso, durante o processo de treinamento e classificação, foi verificado que o tempo de treinamento e classificação aumenta com o aumento das amostras, o que leva a sugerir que menores amostras são suficientes para se ter bons resultados com menor esforço computacional.

Tabela 9 – Acertos Globais da RNA, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área do Centro Politécnico.

Porcentagem Treinamento	Morf.Circ. ALDPAT	Morf.Linear. ALDPAT	Morf.Quad. ALDPAT	Morf.Circ	Morf.Linear	Morf.Quad	Declividade	ETEW	TIN	Pirâmide
5%	0,9885	0,9804	0,9859	0,9842	0,9766	0,9833	0,9863	0,9775	0,9828	0,9866
10%	0,9900	0,9835	0,9878	0,9871	0,9739	0,9861	0,9862	0,9728	0,9848	0,9858
15%	0,9898	0,9847	0,9885	0,9859	0,9780	0,9866	0,9853	0,9778	0,9860	0,9891
20%	0,9899	0,9841	0,9886	0,9855	0,9794	0,9884	0,9872	0,9786	0,9856	0,9879
25%	0,9897	0,9848	0,9891	0,9881	0,9795	0,9878	0,9827	0,9797	0,9864	0,9890
30%	0,9897	0,9854	0,9894	0,9872	0,9788	0,9882	0,9871	0,9795	0,9875	0,9893
35%	0,9899	0,9840	0,9891	0,9877	0,9812	0,9889	0,9865	0,9781	0,9879	0,9883
40%	0,9899	0,9862	0,9887	0,9870	0,9810	0,9876	0,9883	0,9788	0,9881	0,9885
45%	0,9904	0,9853	0,9892	0,9885	0,9799	0,9870	0,9880	0,9800	0,9855	0,9893
50%	0,9900	0,9853	0,9891	0,9887	0,9813	0,9882	0,9887	0,9801	0,9868	0,9887

Tabela 10 – Acertos Globais da RNA, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área da Água Verde / Rebouças.

Porcentagem Treinamento	Morf.Circ. ALDPAT	Morf.Linear. ALDPAT	Morf.Quad. ALDPAT	Morf.Circ	Morf.Linear	Morf.Quad	Declividade	ETEW	TIN	Pirâmide
5%	0,9777	0,9787	0,9784	0,9777	0,9775	0,9784	0,9778	0,9787	0,9792	0,8681
10%	0,9794	0,9796	0,9791	0,9804	0,9785	0,9796	0,9791	0,9791	0,9806	0,8663
15%	0,9792	0,9798	0,9791	0,9806	0,9795	0,9801	0,9799	0,9803	0,9803	0,8702
20%	0,9813	0,9801	0,9798	0,9800	0,9795	0,9790	0,9788	0,9802	0,9804	0,8750
25%	0,9799	0,9812	0,9797	0,9813	0,9792	0,9805	0,9808	0,9802	0,9807	0,9011
30%	0,9804	0,9809	0,9799	0,9801	0,9795	0,9799	0,9805	0,9805	0,9804	0,8736
35%	0,9800	0,9806	0,9796	0,9809	0,9797	0,9796	0,9800	0,9810	0,9813	0,8652
40%	0,9811	0,9808	0,9803	0,9804	0,9803	0,9807	0,9806	0,9805	0,9812	0,8765
45%	0,9811	0,9801	0,9803	0,9800	0,9801	0,9802	0,9805	0,9812	0,9817	0,9024
50%	0,9811	0,9810	0,9803	0,9814	0,9803	0,9808	0,9811	0,9815	0,9813	0,8998




Figura 37 - Acertos Globais da RNA, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área do Centro Politécnico.




Figura 38 - Acertos Globais da RNA, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área da Água Verde / Rebouças (a) com valores do Método de Filtragem de Formação de Pirâmide; (b) sem valores do Método de Filtragem de Formação de Pirâmide.

4.3.2 Support Vector Machine

O mesmo procedimento realizado para a RNA foi executado para o SVM. Para treinamento e classificação, foram utilizados os mesmos dados (informação espectral, intensidade de retorno do *Laser Scanner* e informação altimétrica do MDSn gerado a partir dos métodos de filtragem). Também foi feita a análise sobre a influência do tamanho das amostras de treinamento no resultado final. Matrizes de confusão foram criadas para validação dos resultados, e tabelas e gráficos para visualização dos acertos globais.

A Tabela 11 traz a matriz de confusão gerada a partir da classificação a área do Centro Politécnico com SVM, utilizando 40% de amostras de treinamento, valor de altimetria do MDSn gerado com base no método de filtragem de morfologia matemática, com operador circular, do software ALDPAT. Nesta matriz de confusão, é possível verificar que 154.731 pixels foram classificados pelo autor e SVM como árvores, e 32.260 pixels como não árvores. Houve divergência na classificação em 560 pixels que foram classificados pelo autor como não árvores e pelo SVM como árvores, e 1.277 pixels como árvores pelo autor e não árvores pelo classificador. Com isso, o acerto global foi de 99,03%. Ou seja, 99,03% dos pixels foram classificados pelo autor e pelo classificador na mesma classe.

Tabela 11 – Matriz de Confusão - classificador SVM, com 40% de amostra de treinamento, MDSn a partir do método de Filtragem de morfologia matemática, com operador circular, do software ALDPAT, para a área do Centro Politécnico.

Classes	Árvores	Não Árvores	
Árvores	154.731	1.277	99,18%
Não Árvores	560	32.260	98,29%
	99,64%	96,19%	99,03%

Como exemplo de matriz de confusão para a área da Água Verde / Rebouças é apresentada a Tabela 12, que foi gerada a partir dos resultados da classificação com SVM e 50% de amostra de treinamento, dados altimétricos do MDSn gerado em função dos resultados do método de filtragem utilizando TIN do software ALDPAT.

Novamente, o acerto global é elevado, com 98,16% dos pixels classificados pelo autor e SVM na mesma classe (212.806 como árvores e 71.610 como não árvores).

Tabela 12 – Matriz de Confusão - classificador SVM, com 50% de amostra de treinamento, MDSn a partir do método TIN, do software ALDPAT, para a área da Água Verde / Rebouças.

Classes	Árvores	Não Árvores	
Árvores	212806	3651	98,31%
Não Árvores	1692	71610	97,69%
	99,21%	95,15%	98,16%

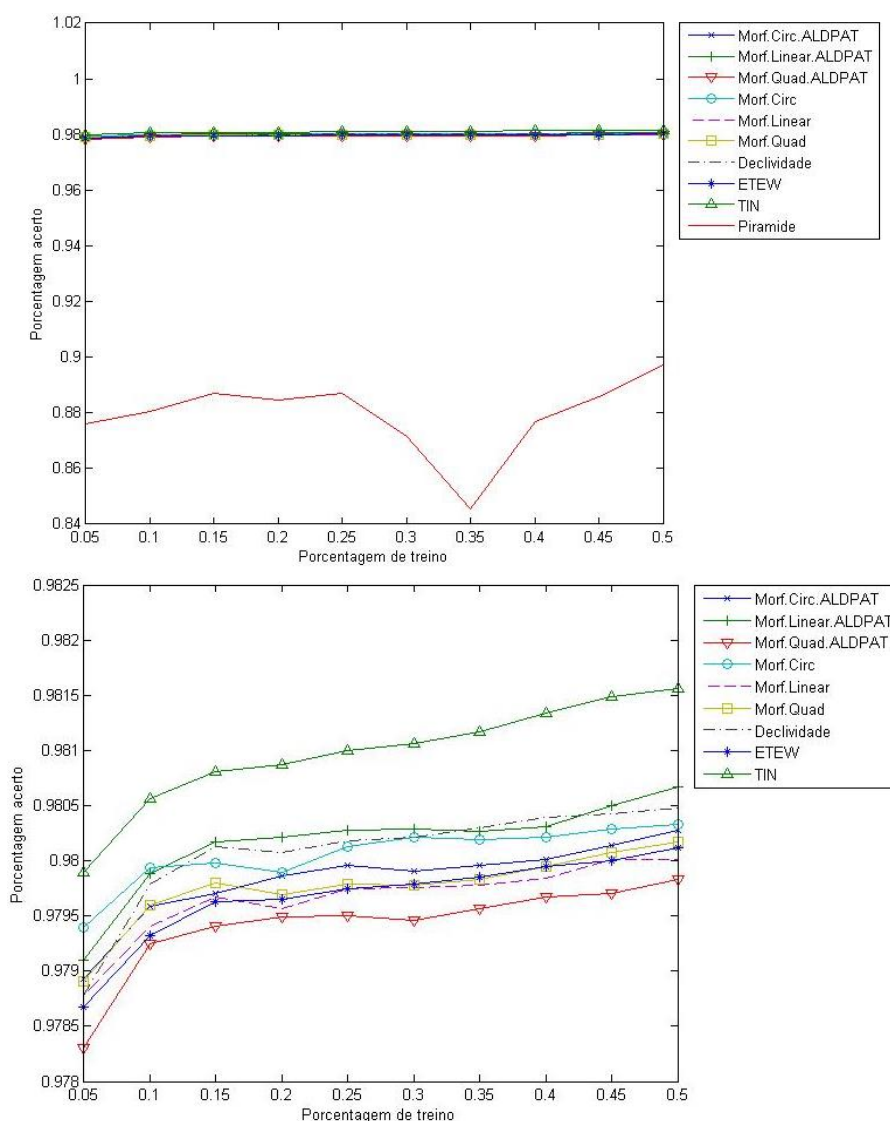

Os acertos globais foram agrupados em função do método de filtragem de dados e tamanho das amostras de treinamento e são apresentados na Tabela 13 e Tabela 14. Estes resultados também são apresentados na Figura 39 e Figura 40, para a área do Centro Politécnico e da Água Verde/ Rebouças, respectivamente. As matrizes de confusão geradas para cada método de filtragem e tamanho das amostras de treinamento estão no APÊNDICE G (pág. 139) e APÊNDICE H (pág. 150), conforme as áreas de estudo.

Tabela 13 – Acertos Globais do SVM, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área do Centro Politécnico.

Porcentagem Treinamento	Morf.Circ. ALDPAT	Morf.Linear. ALDPAT	Morf.Quad. ALDPAT	Morf.Circ	Morf.Linear	Morf.Quad	Declividade	ETEW	TIN	Pirâmide
5%	0,9887	0,9838	0,9877	0,9856	0,9782	0,9859	0,9869	0,9799	0,9852	0,9876
10%	0,9895	0,9844	0,9882	0,9871	0,9791	0,9866	0,9870	0,9807	0,9864	0,9876
15%	0,9900	0,9850	0,9888	0,9874	0,9807	0,9870	0,9882	0,9828	0,9871	0,9885
20%	0,9901	0,9854	0,9890	0,9876	0,9810	0,9873	0,9886	0,9828	0,9874	0,9887
25%	0,9903	0,9853	0,9888	0,9876	0,9806	0,9873	0,9882	0,9828	0,9874	0,9886
30%	0,9901	0,9849	0,9884	0,9875	0,9800	0,9871	0,9874	0,9828	0,9871	0,9879
35%	0,9903	0,9852	0,9885	0,9877	0,9803	0,9872	0,9878	0,9827	0,9875	0,9881
40%	0,9903	0,9852	0,9887	0,9878	0,9806	0,9875	0,9881	0,9829	0,9876	0,9884
45%	0,9902	0,9852	0,9888	0,9879	0,9806	0,9876	0,9881	0,9829	0,9876	0,9883
50%	0,9903	0,9854	0,9890	0,9880	0,9807	0,9877	0,9883	0,9831	0,9878	0,9886

Tabela 14 – Acertos Globais do SVM, conforme o Método de Filtragem e Porcentagem de Amostras utilizadas no Treinamento, para a área da Água Verde / Rebouças.

Porcentagem Treinamento	Morf.Circ. ALDPAT	Morf.Linear. ALDPAT	Morf.Quad. ALDPAT	Morf.Circ	Morf.Linear	Morf.Quad	Declividade	ETEW	TIN	Pirâmide
5%	0,9789	0,9791	0,9783	0,9794	0,9788	0,9789	0,9788	0,9787	0,9799	0,8762
10%	0,9796	0,9799	0,9793	0,9799	0,9794	0,9796	0,9798	0,9793	0,9806	0,8805
15%	0,9797	0,9802	0,9794	0,9800	0,9797	0,9798	0,9801	0,9796	0,9808	0,8870
20%	0,9799	0,9802	0,9795	0,9799	0,9796	0,9797	0,9801	0,9797	0,9809	0,8847
25%	0,9800	0,9803	0,9795	0,9801	0,9797	0,9798	0,9802	0,9797	0,9810	0,8871
30%	0,9799	0,9803	0,9795	0,9802	0,9798	0,9798	0,9802	0,9798	0,9811	0,8715
35%	0,9800	0,9803	0,9796	0,9802	0,9798	0,9798	0,9803	0,9799	0,9812	0,8454
40%	0,9800	0,9803	0,9797	0,9802	0,9798	0,9800	0,9804	0,9800	0,9813	0,8767
45%	0,9801	0,9805	0,9797	0,9803	0,9800	0,9801	0,9804	0,9800	0,9815	0,8858
50%	0,9803	0,9807	0,9798	0,9803	0,9800	0,9802	0,9805	0,9801	0,9816	0,8973



A Figura 39 e Figura 40 foram criadas também com a intenção de demonstrar a variação do acerto global em função do número de amostras de treinamento. Nelas, é possível verificar que há sim um crescimento dos acertos globais com o aumento do número de amostras utilizadas no treinamento. Porém, este crescimento dos acertos não se dá necessariamente constante ou linear com o aumento das amostras.

Além disso, o crescimento nos acertos globais não é considerado tão significativo com o aumento das amostras, uma vez que a utilização de amostras 10 vezes maiores (de 5% para 50%) acarreta numa variação na ordem de apenas 0,2%. Assim, é possível, novamente, concluir que mesmo amostras pequenas (de 5%) já produzem resultados tão bons quanto à utilização de amostras de treinamento maiores (50%, por exemplo).

Também foi verificado durante a fase de treinamento e classificação que conforme se aumenta o número de amostras, maior é o tempo de processamento e esforço computacional. Com a sugestão de utilização de menores quantidades de amostras de treinamento, pode-se ter bons resultados, com tempos de processamento e esforços computacionais menores.

Com relação a tempo de processamento e esforço computacional, também foi verificado que a utilização do classificador SVM necessita de melhores recursos. Os tempos na fase de treinamento foram considerados similares para o SVM e RNA, entretanto, o tempo para classificação com SVM foi significativamente maior. Outro fator que foi analisado neste estudo foi a demanda computacional. A utilização do classificador RNA necessitou de recursos menores, sendo possível a classificação de áreas grandes como da Água Verde / Rebouças em um computador com 3 GB de memória RAM, ou mesmo em um de 2 GB. Já o classificador SVM necessitou de recursos maiores para a classificação da área da Água Verde / Rebouças, por volta de 11 GB de memória RAM.

Sendo assim, como conclusão desta parte do estudo, pode-se sugerir a utilização de amostras menores, mas que sejam representativas da classe, e a utilização do classificador RNA, caso não se disponha de recursos computacionais suficientes, uma vez que RNA demanda menores recursos.

4.4 Filtragem de Árvores

O passo seguinte na metodologia foi a filtragem das árvores nas áreas de estudo. Esta filtragem utilizou, basicamente, os resultados da classificação das árvores pelos classificadores RNA e SVM, onde os pixels correspondentes às árvores foram identificados, e substituídas as informações altimétricas destes pixels pelos valores obtidos depois da interpolação dos valores dos resultados da filtragem dos dados *Laser Scanner*. Ou seja, após a identificação das árvores, o valor altimétrico desses pixels foi substituído pelo valor altimétrico do terreno. Com isso, obtêm-se um Modelo Digital de Superfície filtrado, sem as árvores, denominado, neste trabalho, de Modelo Digital de Superfície Urbano (MDSu).

Exemplos destes Modelos Digitais de Superfície Urbana podem ser vistos nas Figura 41 e Figura 42, para a área do Centro Politécnico e Água Verde / Rebouças, respectivamente. Os demais resultados podem ser vistos no APÊNDICE I (pág.161) e APÊNDICE J (pág.166).

Comparando-se a Figura 41 e Figura 42 (Modelos Digitais de Superfície Urbanos, MDSu) com a Figura 22 (pág. 83) e Figura 28 (pág. 87) (Modelos Digitais de Superfície, MDS), das áreas do Centro Politécnico e Água Verde / Rebouças, respectivamente, percebe-se que boa parte das regiões onde era possível a identificação de feições como árvores foram removidas. Alguns pixels, que, por ventura, foram classificados erroneamente pelos classificadores, foram mantidos ou retirados, o que pode causar “buracos” nas edificações, ou “pontilhados” dos resquícios de árvores que não foram filtradas. Por mais que estes casos estejam presentes em todos os resultados, em maior ou menor grau, estes foram considerados satisfatórios e suficientes para a finalidade a que foram propostos.

Um caso específico que se pode atentar é para a filtragem das árvores presentes na avenida localizada atrás do campo de futebol (Avenida Presidente Getulio Vargas), que cruza diagonalmente a imagem da Figura 42 – acima do campo de futebol. É possível verificar que as árvores, que anteriormente poderiam mascarar, dispersar ou anular o escoamento superficial nas simulações seguintes, foram quase que totalmente filtradas. Assim permite-se que os algoritmos sejam capazes de gerar um resultado mais próximo da realidade, com escoamento sobre esta via.




Figura 41 – Modelo Digital de Superfície do Centro Politécnico, após a filtragem das árvores, utilizando o método de formação de Pirâmide e SVM com treinamento de 50% das amostras.




Figura 42 - Modelo Digital de Superfície da área da Água Verde / Rebouças, após a filtragem das árvores, utilizando o método de morfologia matemática, com operador quadrado, e RNA com treinamento de 50% das amostras.

4.5 Simulação dos Caminhos do Escoamento Superficial

Por fim, foram simulados os caminhos do escoamento superficial sobre os Modelos Digitais de Superfície filtrados, sem as árvores e redes de transmissão de energia, denominados Modelos Digitais de Superfície Urbana (MDSu), para cada área de estudo, com cinco algoritmos. Estes algoritmos de simulação da direção do fluxo do escoamento superficial foram: D8, Rh8, MS, FRh8 e Dinfinito (seção 3.2.5, pág. 72).

A Figura 43 traz os resultados destes algoritmos, para a área do Centro Politécnico, com a utilização de morfologia matemática, com operador quadrado, para filtragem dos dados *Laser Scanner* e classificador SVM com 50% de amostras de treinamento.




Figura 43 – Resultados dos Diferentes Algoritmos de Simulação dos Caminhos do Escoamento Superficial (a) D8; (b) Rh8; (c) MS; (d) FRh8; (e) Dinfinito; todos sobre (f) MDS filtrado, utilizando o Método de Filtragem de Morfologia Matemática, Classificação de Árvores com SVM 50%, para a Área do Centro Politécnico.

Nestas imagens, em preto está o terreno onde o escoamento foi abaixo de 200 pixels contribuintes, e em branco, locais onde o escoamento teve mais que 200 pixels contribuintes.

Como pode ser observado na Figura 43, cada algoritmo apresenta um resultado distinto, para a mesma fonte de dados de altimetria. Ou seja, existe influência significativa no resultado final do conceito utilizado no algoritmo, se este possibilita caminhos únicos, múltiplos ou com fator aleatório.

Na Figura 43(a) é possível verificar a formação de muitos caminhos, por vezes paralelos, não tendo a tendência de agrupar o escoamento. Nesta mesma imagem, é possível verificar que os fluxos acabam por ter muitas regiões de ângulos bem definidos, gerando fluxos “quebrados”. Ao se comparar a Figura 43(a) com a Figura 43(b), percebe-se que o fator aleatório introduzido diminui a quantidade de fluxos paralelos, por mais que estes ainda existam. Entretanto, devido ao fator aleatório, cada vez que o algoritmo fosse utilizado, mesmo que sobre os mesmos dados, produziria resultados diferentes deste apresentado.

É evidente a diferença das imagens da Figura 43(c), (d) e (e) se comparadas com as (a) e (b). As imagens da Figura 43(c), (d) e (e), trazem uma demonstração, intuitivamente, mais real do fluxo, uma vez que os caminhos gerados se assemelham mais ao que era esperado do fluxo de escoamento superficial. Isto se deu, principalmente, devido ao fato do fluxo poder se dividir para mais de uma célula adjacente, até duas células no caso do Dinfinitos, ou até as oito células adjacentes no caso do MS e FRh8.

A Figura 43(c) apresenta o resultado do algoritmo MS, enquanto que a Figura 43(d) do algoritmo FRh8. A diferença entre estes dois algoritmos está novamente no fator aleatório presente no FRh8. Os resultados apresentados se assemelham muito um ao outro, mas é possível verificar que não são iguais. A desvantagem da utilização do FRh8, assim como do Rh8, está em produzir resultados diferentes para os mesmos dados a cada vez que o algoritmo for utilizado, em função do fator aleatório destes algoritmos.

Ainda, pode-se analisar que o algoritmo Dinfinito traz resultados diferentes dos demais, mas, com resultados mais próximos dos métodos que permitem direções múltiplas.

Como conclusão, até esta etapa, pode-se afirmar que realmente os métodos produzem diferentes resultados, em função do conceito utilizado, como a possibilidade de fluxo único, múltiplos ou com fator aleatório. Porém, a desvantagem da utilização desta aleatoriedade torna difícil a geração de mesmos resultados para mesmos conjuntos de dados. Os algoritmos que geraram resultados que poderiam se assemelhar mais com a realidade, foram os que aceitam múltiplos caminhos de fluxo. Ou seja, por mais que algoritmos de caminho único possam ser mais fáceis de serem implementados, com menor custo de processamento, e implementados em diversos softwares de Sistemas de Informação Geográfica (SIG), estes podem apresentar resultados irreais, sendo recomendado que, quando possível, sejam utilizados algoritmos que possibilitam caminhos múltiplos, como o MS ou o Dinfinito.

Na Figura 44 são apresentadas imagens dos resultados de um mesmo algoritmo de simulação da direção do fluxo (MS), utilizando diferentes Modelos Digitais de Superfície Urbana (MDSu), para a mesma área do Centro Politécnico.




Figura 44 – Comparação da Influência dos Diferentes Métodos de Filtragem nos Resultados do Algoritmo de Simulação dos Caminhos do Escoamento Superficial (MS). Classificação de Árvores com SVM 50%. Área do Centro Politécnico. Métodos de Filtragem: (a) Morfologia Matemática, operador quadrado; (b) Morfologia Matemática, operador quadrado, software ALDPAT; (c) Pirâmide; (d) Declividade.

Como pode ser visto na Figura 44, diferentes métodos de filtragem dos dados *Laser Scanner* afetam nos resultados dos algoritmos. Os casos apresentados nesta figura, tratam-se dos resultados do algoritmo MS, considerado anteriormente como um dos algoritmos que pode apresentar resultados mais realistas de fluxo, sobre diferentes Modelos Digitais de Superfície filtrados da área do Centro Politécnico. Os métodos de filtragem apresentados são: (a) Morfologia Matemática com operador quadrador, (b) Morfologia Matemática com operador quadrado do software ALDPAT, (c) Formação de Pirâmide e (d) Declividade.

A explicação para estas variações nos resultados está nos dados de altimetria dos Modelos Digitais de Superfície filtrados, uma vez que, quando filtrados, receberam os valores do terreno que foram interpolados, em função do método de filtragem dos dados *Laser Scanner*. Ou seja, quando feições e terreno eram corrompidos, mais dados deveriam ser interpolados, não preservando os valores originais do *Laser Scanner*. Quando feições sobre o terreno não eram filtrados, estes dados de altimetria mais elevada, como de prédios, poderiam ser utilizados na interpolação dos valores que foram retirados, preenchendo com valores mais elevados que o valor real do terreno.

Sendo assim, é possível dizer que quanto melhor os resultados dos métodos de filtragem, preservando mais informações do terreno e filtrando os objetos acima do mesmo, melhor será o processo de interpolação, onde os dados preenchidos se assemelharão mais com o valor altimétrico do terreno real. Com isso, evita-se que, quando as árvores são filtradas, o valor que é utilizado para preencher este pixel seja um valor altimétrico irreal, como uma depressão ou obstáculo ao fluxo. Portanto, quanto melhor for a filtragem dos dados, melhor será a representação do terreno gerado com o processo de preenchimento por interpolação dos dados filtrados, e quando filtradas as árvores, o valor substituído será mais condizente com a realidade.

Como a filtragem dos dados *Laser Scanner* foi considerada melhor com a metodologia de morfologia matemática, com operador quadrado, por ter filtrado melhor os objetos sobre o terreno e preservando as informações do terreno, e com maiores acertos globais nas matrizes de confusão, a Figura 44(a) foi considerada a que melhor representa o fluxo dentre os resultados utilizando o algoritmo de simulação da direção do escoamento superficial.

Como forma de quantificar os resultados obtidos, e não apenas de forma visual, foram criadas as Tabela 15 e Tabela 16. Estas tabelas trazem uma comparação quantitativa do comprimento dos fluxos gerados pelos algoritmos com um valor de referência. Foram analisados os escoamento em duas ruas no Centro Politecnico que, em função da declividade das mesmas, o fluxo deveria ter, aproximadamente, o mesmo comprimento da via. Ou seja, foram comparados os comprimento do fluxo gerado pelos algoritmos e o comprimento da via analisada, o que pode ser considerado um Coeficiente de Forma do escoamento. A localização destas ruas do Centro Politécnico é apresentada na Figura 45.

Tabela 15 – Comparação entre o comprimento da rua de referencia, Rua 1, e o tamanho do fluxo gerado pelos algoritmos de determinação da direção do fluxo de escoamento superficial.

	Comprimento L (m)	$L_{\text{algoritmo}}/L_{\text{rua}}$
Rua 1	91,735	-
D8	110,380	1,203
Rh8	110,945	1,209
MS	100,929	1,100
FRh8	102,532	1,118
Dinfinito	101,101	1,102

Tabela 16 - Comparação entre o comprimento da rua de referencia, Rua 2, e o tamanho do fluxo gerado pelos algoritmos de determinação da direção do fluxo de escoamento superficial.

	Comprimento L (m)	$L_{\text{algoritmo}}/L_{\text{rua}}$
Rua 2	96,885	-
D8	113,009	1,166
Rh8	112,293	1,159
MS	100,141	1,034
FRh8	102,500	1,058
Dinfinito	100,137	1,034

Como pode ser analisado nas Tabela 15 e Tabela 16, os comprimentos dos resultados do fluxo do escoamento dos algoritmos deram maiores que o comprimento das ruas. É possível classificar estes resultados em dois grupos em função da similaridade dos resultados. O primeiro com os resultados do D8 e Rh8, e o segundo como o MS, FRh8 e Dinfinito. O primeiro grupo, por apresentar fluxos muito lineares e, por vezes, com ângulos retos, apresentou maiores comprimentos, apresentando

resultados muito semelhantes entre si. O segundo grupo apresentou resultados mais próximos do esperado, com Coeficientes de Forma mais próximos ao valor unitário. Ainda, pode-se atentar que os valores do MS e Dinfinito foram mais próximos entre si, e mais próximos do comprimento da via, sendo, novamente, considerados os algoritmos mais indicados para estas análises.




Figura 45 – Localização das ruas utilizadas no comparativo quantitativo dos resultados dos algoritmos de determinação da direção do fluxo de escoamento superficial.

E, por fim, a título de validação da metodologia deste trabalho, é apresentada a Figura 46, onde é comparada a utilização do algoritmo de simulação de direção do escoamento superficial Dinfinito, para a área da Água Verde / Rebouças, sobre os dados:

- (a) do Modelo Digital de Superfície (MDS), apenas com o pré-tratamento dos dados, apresentado na Figura 28, pág.87;
- (b) do Modelo Digital de Superfície Urbana (MDSu), com a utilização do método de morfologia matemática com operador quadrado para filtragem dos dados *Laser Scanner* e classificação das árvores com SVM, com 50% de amostras de treinamento, apresentado na Figura 42, pág. 109.




Figura 46 – Comparação da Influência do Processo de Filtragem das Árvores na Simulação do Escoamento Superficial (Dinfinito). Área da Água Verde / Rebouças (a) MDS; (b) MDSu; (c) Dinfinito sobre a imagem (a); Dinfinito sobre a imagem (b).

Visivelmente, estes resultados apresentados na Figura 46 são diferentes. Isto leva a conclusão de que a filtragem de objetos, como a copa das árvores e redes de transmissão de energia, que permitem que exista escoamento superficial sob as mesmas, mas devido a forma com que são captados pelo sensor *Laser Scanner* podem representar erroneamente obstáculos ao fluxo, influencia diretamente nos resultados dos algoritmos. Esta é uma região com ruas bem arborizadas, e, na comparação destes resultados, com e sem a filtragem das árvores, é possível a identificação da alteração dos padrões de escoamento, principalmente sobre as ruas. Além disso, percebe-se que uma região que sofreu bastante influência deste processo de filtragem, foi o escoamento na região da avenida localizada atrás do campo de futebol (Av. Pres. Getúlio Vargas, mencionada

anteriormente). Nesta avenida, sem a filtragem das árvores, Figura 46(a), o resultado tende a formar um fluxo saindo desta via e passando por uma rua concorrente a mesma, na lateral ao campo de futebol, enquanto que, com a filtragem, Figura 46(b), o fluxo passa por trás do campo.

Ou seja, esta metodologia de identificação e filtragem de objetos que permitem a passagem do fluxo de escoamento superficial sob os mesmos, mas com a utilização dos dados *Laser Scanner* podem apresentar-se como obstáculos ao fluxo, influencia significativamente os resultados das simulações. Com esta metodologia, aproximam-se os resultados das simulações feitas com os algoritmos de determinação de direção do fluxo de escoamento aos padrões reais de escoamento superficial, o que pode contribuir significativamente para o melhor entendimento destes padrões de escoamento, ou mesmo, a utilização destes resultados em outras análises, como delimitações de microbacias urbanas, regiões de tendência de acumulação de fluxo, caminhos possíveis para transporte de poluentes, etc.

5 Considerações Finais

Neste trabalho foi discutida uma metodologia para simulações da direção do fluxo do escoamento superficial, utilizando dados *Laser Scanner* e imagens de alta resolução. Foi concluído que, em dados de alta resolução, como os utilizados, são necessários alguns processos para que se possa utilizar os algoritmos de determinação da direção do fluxo, para que estes gerem resultados mais próximos da realidade. Basicamente, ao se utilizar estes dados, o maior problema encontrado está em feições que podem ser representados pelo *Laser Scanner* como obstáculos ao fluxo, mas que na verdade não são, como redes de transmissão de energia ou copa das árvores. Para solução deste problema foram utilizados e comparados diferentes métodos, de forma a se ter melhores resultados, mais próximos da realidade, e com maior eficiência. Foram utilizados métodos de filtragem dos dados *Laser Scanner* para a Geração do Modelo Digital do Terreno (MDT) e Modelo Digital de Superfície Normalizado (MDSn), assim como classificadores digitais de imagens, baseados em inteligência artificial, como as Redes Neurais Artificiais (RNA) e *Support Vector Machine* (SVM).

Como conclusões de cada parte da metodologia, foi identificado que:

- o método de morfologia matemática foi considerado como um dos melhores, trazendo bons resultados e sendo um método semi automático, com poucos parâmetros, podendo ser implementado em softwares de programação, ou já implementado em outros softwares, como o ALDPAT;
- classificadores digitais de imagens, baseados em inteligência artificial, apresentaram ótimos resultados, todos com acertos globais acima de 80%, e a grande maioria acima de 95% de acerto global;
- o classificador baseado em Redes Neurais Artificiais apresentou maior facilidade de treinamento e classificação que o baseado em *Support Vector Machine*, ambos apresentando as mesmas faixas de acertos globais;
- a variação do tamanho das amostras de treinamento dos classificadores alterou pouco os acertos globais, sendo encontrado que amostras de

treinamento até menores que 2% da imagem original, utilizando dados altimétricos e espectrais, produziram acertos globais de até 97,99%;

- e, por fim, que algoritmos de determinação da direção do fluxo do escoamento superficial que utilizam o conceito de múltiplas direções, permitindo para todos os vizinhos (MS), ou para, no máximo, dois deles (Dinfinito), produziram fluxos que se assemelham mais com a realidade, enquanto que os algoritmos de direção única produzem fluxos interrompidos, muito lineares ou paralelos, apresentando-se irrealistas.

Ao final, concluiu-se que a filtragem de elementos, como redes de transmissão de energia e árvores, influencia nos resultados dos algoritmos de determinação da direção do fluxo, quando são utilizados dados de alta resolução, gerando resultados mais próximos da realidade. Sendo assim, recomenda-se que se sigam estes processos para melhor modelagem da direção do fluxo de escoamento, quando utilizados dados de alta resolução, principalmente os obtidos por *Laser Scanner*. Ou seja, para melhor representação da realidade, que os algoritmos de determinação do fluxo do escoamento superficial sejam utilizados em Modelos Digitais de Superfície Urbana (MDSu), e não diretamente sobre o Modelo Digital de Superfície (MDS).

Como recomendações para trabalhos futuros, sugere-se testes com outros métodos de filtragem dos dados *Laser Scanner*, sendo implementados em softwares de programação ou já implementados em outros softwares; outros classificadores, paramétricos ou não paramétricos, supervisionados ou não, com diferentes dados, além do espectral e altimétrico; e, até mesmo, outros algoritmos de determinação da direção do fluxo, comparando com os implementados em softwares de Sistemas de Informações Geográficas (SIG), como o ArcGIS.

6 Referências Bibliográficas

ALES, V. T., **O Algoritmo Sequential Minimal Optimisation para Resolução do Problema de Support Vector Machine: Uma Técnica para Reconhecimento de Padrões**. Dissertação de Mestrado, Universidade Federal do Paraná. 2008.

ALONSO, M. C., MALPICA, J. A., **Classification of Multispectral High-Resolution Satellite Imagery Using LIDAR Elevation Data**. Springer-Verlag Berlin Heidelberg, 2008.

ALONSO, M. C., MALPICA, J. A., **Satellite Imagery Classification with Lidar Data**. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science, Volume XXXVIII, Part 8, Kyoto, Japan. 2010.

ANDREOLA, R., HAERTEL, V., **Support Vector Machines na Classificação de Imagens Hiperespectrais**. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal. 2009.

ARAKI, H., **Fusão de Informações Espectrais, Altimétricas e de Dados Auxiliares na Classificação de Imagens de Alta Resolução Espacial**. Tese de Doutorado. Curso de Pós-Graduação em Ciências Geodésicas. Universidade Federal do Paraná, 2005.

BALTSAVIAS, E. P., **Airborne laser scanning: basic relations and formulas**. ISPRS Journal of Photogrammetry and Remote Sensing, 54.2, 1999.

BEALE, M. H., HAGAN, M. T., DEMUTH, H. B., **Neural Network Toolbox User's Guide**. The MathWorks, Inc. 2011.

BOTELHO, M. F., **Aplicação de Redes Neurais na Classificação de Imagens de Alta Resolução Espacial e Dados do *Laser Scanner*, Usando uma Abordagem Orientada a Regiões**. Dissertação de Mestrado. Universidade Federal do Paraná, 2004.

BRANDÃO, T. F., SANTOS, R. L., **O Uso de Imagens SRTM na Modelagem de Fenômenos Hidrológicos (Escoamento Superficial)**. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto. Natal, 2009.

BROWN, M., GUNN, S. R., LEWIS, H. G., **Support Vector Machines for Optimal Classification and Spectral Unmixing**. Ecological Modelling, 120. 1999.

BUARQUE, D. C., FAN, F. M., PAZ, A. R., COLLISCHONN, W., **Comparação de Métodos para Definir Direções de Escoamento a partir de Modelos Digitais de Elevação.** Revista Brasileira de Recursos Hídricos vol. 14, n.2. 2009.

BURGES, C. J. C., **A Tutorial on Support Vector Machines for Pattern Recognition.** Data Mining and Knowledge Discovery, 2. 1998.

CENTENO, J. A. S., KISHI, R. T., MITISHITA, E. A., **Aplicação de *Laser Scanner* para detecção de áreas para coleta de água de chuva.** Anais XIV Simpósio Brasileiro de Sensoriamento Remoto. Natal, 2009.

CENTENO, J. A. S., MITISHITA, E. A., ***Laser Scanner* Aerotransportado no Estudo de Áreas Urbanas: A Experiência da UFPR.** Anais XIII Simpósio Brasileiro de Sensoriamento Remoto. Florianópolis, 2007.

CENTENO, J. A. S., **Sensoriamento Remoto e Processamento de Imagens Digitais.** Editora Curso de Pós-Graduação em Ciências Geodésicas. Universidade Federal do Paraná. Curitiba, 2009.

CHANG, Y. C., HABIB, A. F., LEE, D. C., YOM, J.H., **Automatic Classification of Lidar Data into Ground and Non-Ground Points.** The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. Vol. XXXVII. Part B4. Beijing, 2008.

CHETTRI, S. R., CROMP, R. F., BIRMINGHAM, M., **Design of Neural Networks for Classification of Remotely Sensed Imagery.** Telematics and Informatics. vol. 9, nº. 3/4. 1992.

COELHO, A. H., VÖGTLE, T., WEINDORF, M., BÄHR, H. P., **Utilização do Método de Pirâmide de Imagens para a Extração de Modelos Digitais de Terreno de Imagens Geradas por Dados de *Laser Scanner*.** COBRAC - Congresso Brasileiro de Cadastro Técnico Multifinalitário. UFSC, Florianópolis, 2002.

COSTA, L. M. M., ZEILHOFER, P., RODRIGUES, W. S., **Avaliação do Classificador SVM (Support Vector Machine) no Mapeamento de Queimadas no Pantanal Mato-Grossense.** III Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação. 2010.

CROMBEZ, K. M., **Comparing Flow Routing Algorithms for Digital Elevation Models.** Digital Terrain Analysis, Geo428, 2008.

DEUS, L. R., ALFAYA, F. A. V. S., SOUZA, U. D. V., TOMÁS, L. R., FONSECA, L. M. G., **Deteção de Edificações em Áreas Urbanas por Meio de Classificação de Pontos LIDAR.** Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, 2011.

EGMONT-PETERSEN, M., RIDDER, D. DE, HANDELS, H., **Image Processing with Neural Networks—A Review.** Pattern Recognition, 35. 2002.

ELLIS, B., VIAVATTENE, C., REVITT, M., PETERS, C., SEIKER, H., **A Modelling Approach to Support the Management of Flood and Pollution Risks for Extreme Events in Urban Stormwater Drainage Systems.** 4th SWITCH Scientific Meeting, Delft, 2009.

ENDRENY, T. A., WOOD, E. F., **Maximizing Spatial Congruence of Observed and DEM-Delineated Overland Flow Networks.** Int J. Geographical Information Science, vol. 17, nº 7. 2003.

ERSKINE, R. H., GREEN, T. R., RAMIREZ, J. A., MACDONALD, L. H., **Comparison of Grid-Based Algorithms for Computing Upslope Contributing Area.** Water Resources Research, vol. 42, 2006.

EVGENIOU, T., PONTIL, M., **Support Vector Machines: Theory and Applications.** Machine Learning and Its Applications. Lecture Notes in Computer Science. Volume 2049, 2001.

FAZAN, A. J., POZ, A. P. D., **Extração de Contornos Aproximados de Telhados de Edifícios a Partir de Dados de Varredura a Laser.** Anais XV Simpósio Brasileiro de Sensoriamento Remoto – SBSR. Curitiba, 2011.

FOODY, G. M., MATHUR, A., **A Relative Evaluation of Multiclass Image Classification by Support Vector Machines.** Transactions on Geoscience and Remote Sensing, vol. 42, nº. 6. 2004.

FOODY, G. M., MATHUR, A., **Toward Intelligent Training of Supervised Image Classifications: Directing Training Data Acquisition for SVM Classification.** Remote Sensing of Environment, 93. 2004 b.

HEERMANN, P. D., KHAZENIE, N., **Classification of Multispectral Remote Sensing Data Using a Back-Propagation Neural Network.** Transactions on Geoscience and Remote Sensing. Vol. 30, nº. I, 1992

JARVIS, C. H., STUART, N., **The Sensitivity of a Neural Network for Classifying Remotely Sensed Imagery**. Computers and Geosciences. Vol. 22, No. 9. 1996.

JÚNIOR, W. P. S., **Modelagem Espacial de Fluxo de Água Utilizando Autômatos Híbridos**. Dissertação de Mestrado. Centro Universitário de Anápolis. Anápolis, 2009.

KAVZOGLU, T., COLKESEN, I., **A Kernel Functions Analysis for Support Vector Machines for Land Cover Classification**. International Journal of Applied Earth Observation and Geoinformation, 11. 2009.

LEK, S., GUÉGAN, J.F., **Artificial Neural Networks as a Tool in Ecological Modelling, An Introduction**. Ecological Modelling, 120. 1999.

LODHA, S. K., KREPS, E. J., HELMBOLD, D. P., FITZPATRICK, D., **Aerial LiDAR Data Classification using Support Vector Machines (SVM)**. Proc. IEEE Symp. 3D Data Processing, Visualization, and Transmission, IEEE Press. 2006.

LOU, R. F., **Modelagem Hidrológica Chuva-Vazão e Hidrodinâmica Aplicada na Bacia Experimental do Rio Piabanha/RJ**. Tese de Doutorado. Universidade Federal do Rio de Janeiro, 2010.

MOUNTRAKIS, G., IM, J., OGOLE, C., **Support vector machines in remote sensing - A review**. ISPRS Journal of Photogrammetry and Remote Sensing, 66. 2011.

NASCIMENTO, R. F. F., ALCÂNTARA, E. H., KAMPEL, M., STECH, J. L., NOVO, E. M. L. M., FONSECA, L. M. G., **O Algoritmo Support Vector Machines (SVM): Avaliação da Separação Ótima de Classes em Imagens CCD-CBERS-2**. Anais XIV Simpósio Brasileiro de Sensoriamento Remoto, Natal. 2009.

PAL, M., MATHER, P.M., **Assessment of the Effectiveness of Support Vector Machines for Hyperspectral Data**. Future Generation Computer Systems, 20. 2004.

PAOLA, J. D., SCHOWENGERDT, R. A., **A Detailed Comparison of Backpropagation Neural Network and Maximum-Likelihood Classifiers for Urban Land Use Classification**. Transactions on Geoscience and Remote Sensing, vol. 33, nº. 4, 1995.

PAZ, A. R., COLLISCHONN, W., **Derivação de Rede de Drenagem a Partir de Dados do SRTM**. Rev. Geogr. Acadêmica v.2 n.2 2008.

PETROPOULOS, G. P., ARVANITIS, K., SIGRIMIS, N., **Hyperion Hyperspectral Imagery Analysis Combined with Machine Learning Classifiers for Land Use/Cover Mapping**. Expert Systems with Applications, 39. 2012.

QIN, C.Z., ZHAN, L., **Parallelizing Flow-Accumulation Calculations on Graphics Processing Units—From Iterative DEM Preprocessing Algorithm to Recursive Multiple-Flow-Direction Algorithm**. Computers & Geosciences, Vol. 43, 2012.

QUINN, P., BEVEN, K., CHEVALLIER, P., PLANCHON, O., **The Prediction of Hillslope Flow Paths for Distributed Hydrological Modeling Using Digital Terrain Models**. Hydrological Processes, 5, 1991.

ROTTENSTEINER, F., BRIESE, C.H., **A New Method for Building Extraction in Urban Areas From High-Resolution Lidar Data**. International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences, 34.3/A3, 2002.

SULEIMAN, H. C., BARBASSA, A. P., **Mapeamento Preliminar de Áreas Urbanas de Inundação**. Revista Ciência & Engenharia, nº 15, 2005.

TARBOTON, D. G., **A New Method for the Determination of Flow Directions and Upslope Areas in Grid Digital Elevation Models**. Water Resources Research, 33(2). 1997.

TUCCI, C. E. M., BERTONI, J. C., **Inundações Urbanas na América do Sul**. Porto Alegre: Associação Brasileira de Recursos Hídricos, 2003.

WEIDNER, U., FÖRSTNER, W., **Towards automatic building extraction from high resolution digital elevation models**. ISPRS Journal of Photogrammetry and Remote Sensing, 50, 4, 1995.

WILSON, J. P., AGGETT, G., DENG, Y., LAM, C. S., **Water in the Landscape: A Review of Contemporary Flow Routing Algorithms**. Advances in digital terrain analysis, 2008.

ZHANG, K., CHEN S. C., WHITMAN, D., SHYU, M. L., YAN, J., ZHANG, C., **A Progressive Morphological Filter for Removing Nonground Measurements From Airborne LIDAR Data**. Transactions on Geoscience and Remote Sensing, vol. 41, nº 4, 2003.

ZHANG, K., CUI, Z., **Airborne LIDAR Data Processing and Analysis Tools: ALDPAT 1.0**. National Center for Airborne Laser Mapping. Florida International University. 2007.

7 Apêndices

APÊNDICE A - Imagem dos Modelos Digitais do Terreno (MDT) gerados pelos Métodos de Filtragem para a Área do Centro Politécnico - UFPR, Curitiba - PR.....	127
APÊNDICE B – Matrizes de Confusão para os Métodos de Filtragem para geração dos Modelos Digitais do Terreno (MDT) para a Área do Centro Politécnico - UFPR, Curitiba - PR.....	129
APÊNDICE C - Imagem dos Modelos Digitais de Superfície Normalizados (MDSn) obtidos pela subtração do Modelo Digital de Superfície (MDS) e Modelos Digital de Terreno (MDT) gerados pelos Métodos de Filtragem para a Área do Centro Politécnico - UFPR, Curitiba - PR.....	131
APÊNDICE D - Imagem dos Modelos Digitais do Terreno (MDT) gerados pelos Métodos de Filtragem para a Área da Água Verde – Rebouças, Curitiba - PR	133
APÊNDICE E – Matrizes de Confusão para os Métodos de Filtragem para geração dos Modelos Digitais do Terreno (MDT) para a Área da Água Verde – Rebouças, Curitiba - PR.....	135
APÊNDICE F - Imagem dos Modelos Digitais de Superfície Normalizados (MDSn) obtidos pela subtração do Modelo Digital de Superfície (MDS) e Modelos Digital de Terreno (MDT) gerados pelos Métodos de Filtragem para a Área da Água Verde – Rebouças, Curitiba - PR.....	137
APÊNDICE G - Matriz de Confusão da Classificação com <i>Support Vector Machine</i> e Redes Neurais Artificiais, para treinamento de 5%, 10%, 15%, 20%, 25%, 30%, 35%, 40%, 45%, 50%, e os métodos de filtragem, para a Área do Centro Politécnico - UFPR, Curitiba - PR.....	139
APÊNDICE H - Matriz de Confusão da Classificação com <i>Support Vector Machine</i> e Redes Neurais Artificiais, para treinamento de 5%, 10%, 15%, 20%, 25%, 30%, 35%, 40%, 45%, 50%, e os métodos de filtragem, para a Área da Água Verde – Rebouças, Curitiba - PR.....	150
APÊNDICE I - Imagem dos Resultados da Filtragem das Árvores (Modelos Digitais de Superfície Urbana – MDSu), dos classificadores Redes Neurais Artificiais e <i>Support</i>	

<i>Vector Machine</i> , com treinamento de 5% e 50%, e métodos de filtragem, para a Área do Centro Politécnico - UFPR, Curitiba - PR	161
APÊNDICE J - Imagem dos Resultados da Filtragem das Árvores (Modelos Digitais de Superfície Urbana – MDSu), dos classificadores Redes Neurais Artificiais e <i>Support Vector Machine</i> , com treinamento de 5% e 50%, e métodos de filtragem, para a Área da Água Verde – Rebouças, Curitiba - PR	166
APÊNDICE K - Imagem dos Resultados dos Modelos de Simulação de Escoamento Superficial sobre os Modelos Digitais de Superfície Urbana (MDSu) da Área do Centro Politécnico - UFPR, Curitiba - PR.....	171
APÊNDICE L - Imagem dos Resultados dos Modelos de Simulação de Escoamento Superficial sobre os Modelos Digitais de Superfície Urbana (MDSu) da Área da Água Verde – Rebouças, Curitiba - PR.....	177

APÊNDICE A - Imagem dos Modelos Digitais do Terreno (MDT) gerados pelos
Métodos de Filtragem para a Área do Centro Politécnico - UFPR, Curitiba - PR




Figura A1 – Imagem dos Resultados dos Métodos de Filtragem: (a) ETEW; (b) morfC; (c) morfCALDPAT; (d) morfI; (e) morfLALDPAT; (f) morfQ; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.

APÊNDICE B – Matrizes de Confusão para os Métodos de Filtragem para geração dos Modelos Digitais do Terreno (MDT) para a Área do Centro Politécnico - UFPR, Curitiba - PR

Tabela 1 - ETEW

	Terreno	Não Terreno	
Terreno	339874	39197	89,66%
Não Terreno	38975	178739	82,10%
	89,71%	82,01%	86,90%

Tabela 2 - TIN

	Terreno	Não Terreno	
Terreno	348484	7739	97,83%
Não Terreno	30365	210197	87,38%
	91,98%	96,45%	93,62%

Tabela 3 - Slope

	Terreno	Não Terreno	
Terreno	323800	18397	94,62%
Não Terreno	55049	199539	78,38%
	85,47%	91,56%	87,69%

Tabela 4 - morfCALD

	Terreno	Não Terreno	
Terreno	367250	17646	95,42%
Não Terreno	11599	200290	94,53%
	96,94%	91,90%	95,10%

Tabela 5 - morfLALD

	Terreno	Não Terreno	
Terreno	324696	4569	98,61%
Não Terreno	54153	213367	79,76%
	85,71%	97,90%	90,16%

Tabela 6 - morfQALD

	Terreno	Não Terreno	
Terreno	357571	10898	97,04%
Não Terreno	21278	207038	90,68%
	94,38%	95,00%	94,61%

Tabela 7 - morfC

	Terreno	Não Terreno	
Terreno	363531	12074	96,79%
Não Terreno	15318	205862	93,07%
	95,96%	94,46%	95,41%

Tabela 8 - morfI

	Terreno	Não Terreno	
Terreno	362613	18062	95,26%
Não Terreno	16236	199874	92,49%
	95,71%	91,71%	94,25%

Tabela 9 - morfQ

	Terreno	Não Terreno	
Terreno	364977	13294	96,49%
Não Terreno	13872	204642	93,65%
	96,34%	93,90%	95,45%

Tabela 10 - pir

	Terreno	Não Terreno	
Terreno	355031	14023	96,20%
Não Terreno	23818	203913	89,54%
	93,71%	93,57%	93,66%

APÊNDICE C - Imagem dos Modelos Digitais de Superfície Normalizados (MDSn) obtidos pela subtração do Modelo Digital de Superfície (MDS) e Modelos Digital de Terreno (MDT) gerados pelos Métodos de Filtragem para a Área do Centro Politécnico
- UFPR, Curitiba - PR




Figura B1 – Imagem dos MDSn gerados a partir de cada resultado dos Métodos de Filtragem: (a) ETEW; (b) morfc; (c) morfCALDPAT; (d) morfl; (e) morflALDPAT; (f) morfq; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.

APÊNDICE D - Imagem dos Modelos Digitais do Terreno (MDT) gerados pelos
Métodos de Filtragem para a Área da Água Verde – Rebouças, Curitiba - PR

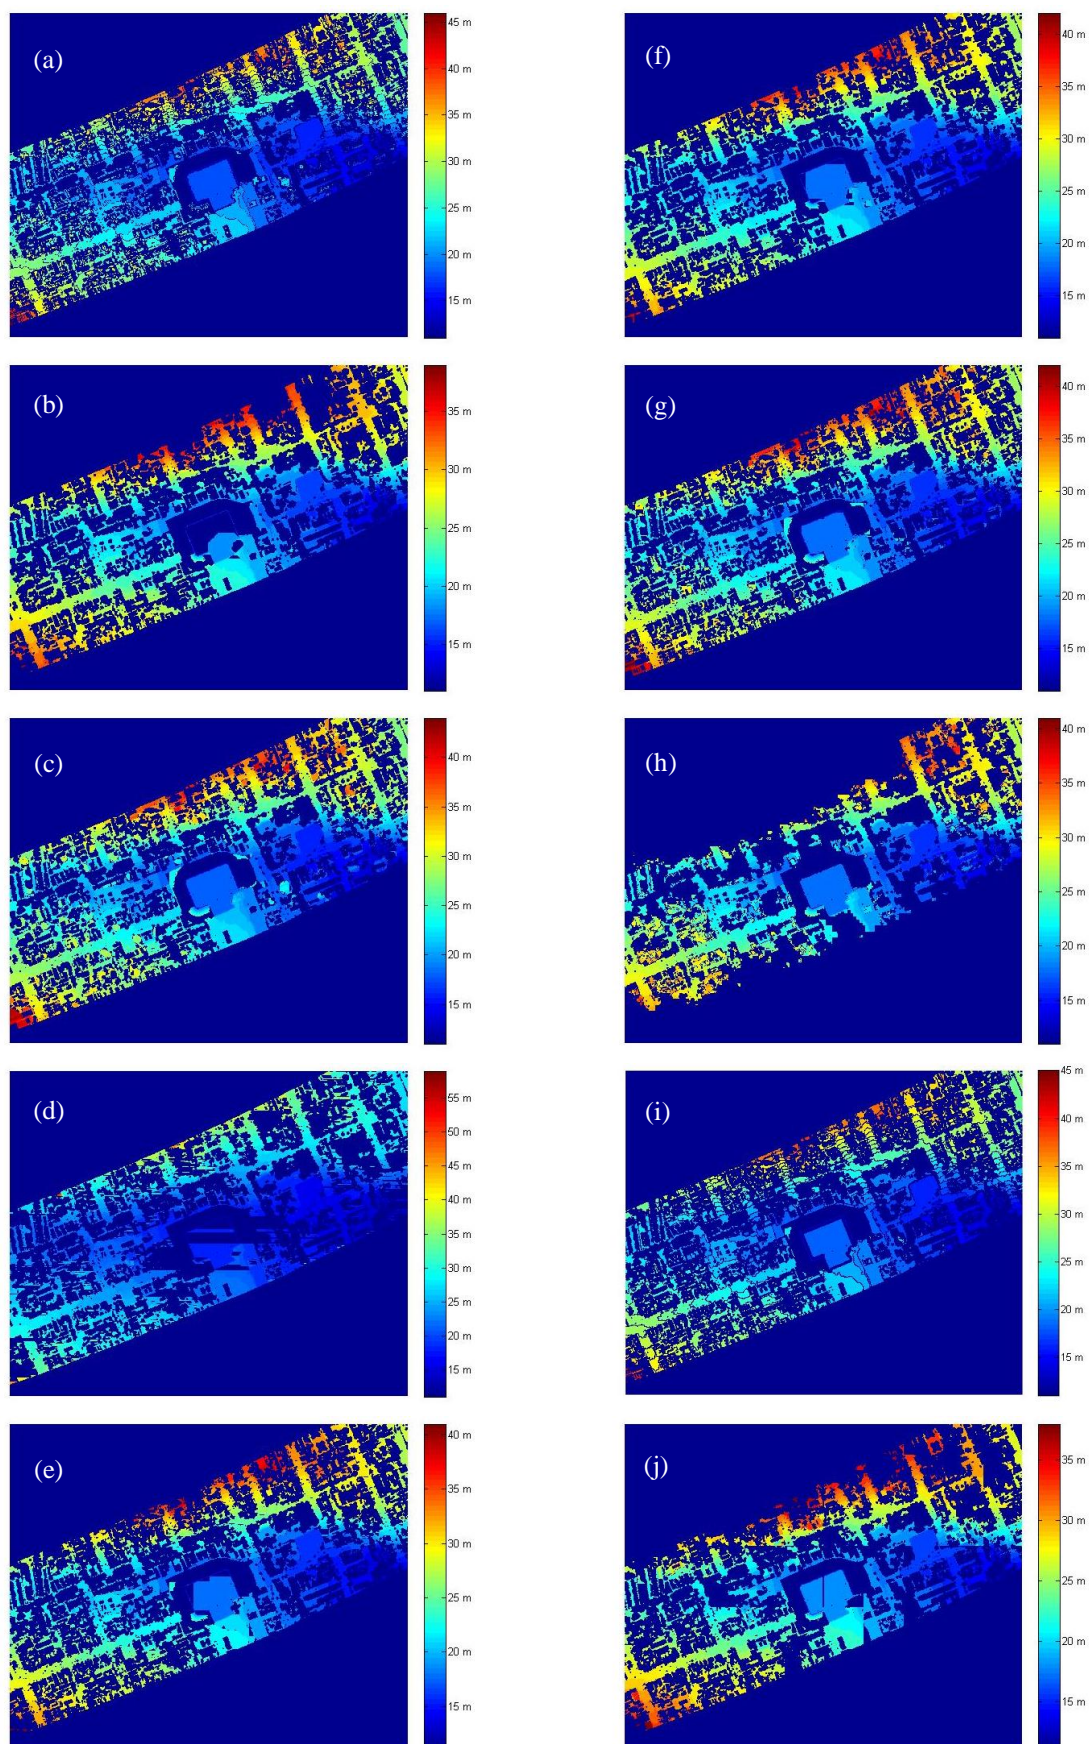


Figura C1 – Imagem dos Resultados dos Métodos de Filtragem: (a) ETEW; (b) morfrc; (c) morfCALDPAT; (d) morfll; (e) morfLALDPAT; (f) morfqr; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.

APÊNDICE E – Matrizes de Confusão para os Métodos de Filtragem para geração dos Modelos Digitais do Terreno (MDT) para a Área da Água Verde – Rebouças, Curitiba - PR

Tabela 1 - ETEW

	Terreno	Não Terreno	
Terreno	704776	82036	89,57%
Não Terreno	198506	918994	82,24%
	78,02%	91,80%	85,27%

Tabela 2 - TIN

	Terreno	Não Terreno	
Terreno	684360	43371	94,04%
Não Terreno	218922	957659	81,39%
	75,76%	95,67%	86,23%

Tabela 3 - Slope

	Terreno	Não Terreno	
Terreno	626431	34947	94,72%
Não Terreno	276851	966083	77,73%
	69,35%	96,51%	83,63%

Tabela 4 - morfCALD

	Terreno	Não Terreno	
Terreno	826920	145538	85,03%
Não Terreno	76362	855492	91,81%
	91,55%	85,46%	88,35%

Tabela 5 - morfLALD

	Terreno	Não Terreno	
Terreno	708535	36412	95,11%
Não Terreno	194747	964618	83,20%
	78,44%	96,36%	87,86%

Tabela 6 - morfQALD

	Terreno	Não Terreno	
Terreno	795872	92731	89,56%
Não Terreno	107410	908299	89,43%
	88,11%	90,74%	89,49%

Tabela 7 - morfc

	Terreno	Não Terreno	
Terreno	728890	59786	92,42%
Não Terreno	174392	941244	84,37%
	80,69%	94,03%	87,70%

Tabela 8 - morfl

	Terreno	Não Terreno	
Terreno	709062	64411	91,67%
Não Terreno	194220	936619	82,83%
	78,50%	93,57%	86,42%

Tabela 9 - morfQ

	Terreno	Não Terreno	
Terreno	774974	58970	92,93%
Não Terreno	128308	942060	88,01%
	85,80%	94,11%	90,17%

Tabela 10 - pir

	Terreno	Não Terreno	
Terreno	645143	94488	87,22%
Não Terreno	258139	906542	77,84%
	71,42%	90,56%	81,48%

APÊNDICE F - Imagem dos Modelos Digitais de Superfície Normalizados (MDSn) obtidos pela subtração do Modelo Digital de Superfície (MDS) e Modelos Digital de Terreno (MDT) gerados pelos Métodos de Filtragem para a Área da Água Verde – Rebouças, Curitiba - PR




Figura D1 – Imagem dos MDSn gerados a partir de cada resultado dos Métodos de Filtragem: (a) ETEW; (b) morfc; (c) morfCALDPAT; (d) morfl; (e) morfLALDPAT; (f) morfq; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.

APÊNDICE G - Matriz de Confusão da Classificação com *Support Vector Machine* e Redes Neurais Artificiais, para treinamento de 5%, 10%, 15%, 20%, 25%, 30%, 35%, 40%, 45%, 50%, e os métodos de filtragem, para a Área do Centro Politécnico - UFPR, Curitiba - PR

Tabela 1 - SVM005_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154658	1350	99,13%
Não Árvores	785	32035	97,61%
	99,49%	95,96%	98,87%

Tabela 2 - SVM010_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154705	1303	99,16%
Não Árvores	680	32140	97,93%
	99,56%	96,10%	98,95%

Tabela 3 - SVM015_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154772	1236	99,21%
Não Árvores	650	32170	98,02%
	99,58%	96,30%	99,00%

Tabela 4 - SVM020_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154774	1234	99,21%
Não Árvores	635	32185	98,07%
	99,59%	96,31%	99,01%

Tabela 5 - SVM025_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154771	1237	99,21%
Não Árvores	596	32224	98,18%
	99,62%	96,30%	99,03%

Tabela 6 - SVM030_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154718	1290	99,17%
Não Árvores	574	32246	98,25%
	99,63%	96,15%	99,01%

Tabela 7 - SVM035_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154734	1274	99,18%
Não Árvores	567	32253	98,27%
	99,63%	96,20%	99,03%

Tabela 8 - SVM040_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154731	1277	99,18%
Não Árvores	560	32260	98,29%
	99,64%	96,19%	99,03%

Tabela 9 - SVM045_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154701	1307	99,16%
Não Árvores	544	32276	98,34%
	99,65%	96,11%	99,02%

Tabela 10 - SVM050_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154724	1284	99,18%
Não Árvores	543	32277	98,35%
	99,65%	96,17%	99,03%

Tabela 11 - SVM005_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	153742	2266	98,55%
Não Árvores	789	32031	97,60%
	99,49%	93,39%	98,38%

Tabela 12 - SVM010_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	153746	2262	98,55%
Não Árvores	693	32127	97,89%
	99,55%	93,42%	98,44%

Tabela 13 - SVM015_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	153826	2182	98,60%
Não Árvores	644	32176	98,04%
	99,58%	93,65%	98,50%

Tabela 14 - SVM020_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	153845	2163	98,61%
Não Árvores	603	32217	98,16%
	99,61%	93,71%	98,54%

Tabela 15 - SVM025_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	153773	2235	98,57%
Não Árvores	546	32274	98,34%
	99,65%	93,52%	98,53%

Tabela 16 - SVM030_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	153687	2321	98,51%
Não Árvores	524	32296	98,40%
	99,66%	93,30%	98,49%

Tabela 17 - SVM035_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	153732	2276	98,54%
Não Árvores	522	32298	98,41%
	99,66%	93,42%	98,52%

Tabela 18 - SVM040_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	153726	2282	98,54%
Não Árvores	512	32308	98,44%
	99,67%	93,40%	98,52%

Tabela 19 - SVM045_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	153722	2286	98,53%
Não Árvores	500	32320	98,48%
	99,68%	93,39%	98,52%

Tabela 20 - SVM050_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	153759	2249	98,56%
Não Árvores	499	32321	98,48%
	99,68%	93,49%	98,54%

Tabela 21 - SVM005_morf.Quad. ALDPAT

	Árvores	Não Árvores	
Árvores	154502	1506	99,03%
Não Árvores	817	32003	97,51%
	99,47%	95,51%	98,77%

Tabela 22 - SVM010_morf.Quad. ALDPAT

	Árvores	Não Árvores	
Árvores	154471	1537	99,01%
Não Árvores	688	32132	97,90%
	99,56%	95,43%	98,82%

Tabela 23 - SVM015_morf.Quad. ALDPAT

	Árvores	Não Árvores	
Árvores	154571	1437	99,08%
Não Árvores	669	32151	97,96%
	99,57%	95,72%	98,88%

Tabela 24 - SVM020_morf.Quad. ALDPAT

	Árvores	Não Árvores	
Árvores	154552	1456	99,07%
Não Árvores	627	32193	98,09%
	99,60%	95,67%	98,90%

Tabela 25 - SVM025_morf.Quad. ALDPAT

	Árvores	Não Árvores	
Árvores	154473	1535	99,02%
Não Árvores	578	32242	98,24%
	99,63%	95,46%	98,88%

Tabela 26 - SVM030_morf.Quad. ALDPAT

	Árvores	Não Árvores	
Árvores	154364	1644	98,95%
Não Árvores	554	32266	98,31%
	99,64%	95,15%	98,84%

Tabela 27 - SVM035_morf.Quad. ALDPAT

	Árvores	Não Árvores	
Árvores	154387	1621	98,96%
Não Árvores	546	32274	98,34%
	99,65%	95,22%	98,85%

Tabela 28 - SVM040_morf.Quad. ALDPAT

	Árvores	Não Árvores	
Árvores	154412	1596	98,98%
Não Árvores	531	32289	98,38%
	99,66%	95,29%	98,87%

Tabela 29 - SVM045_morf.Quad. ALDPAT

	Árvores	Não Árvores	
Árvores	154413	1595	98,98%
Não Árvores	513	32307	98,44%
	99,67%	95,30%	98,88%

Tabela 30 - SVM050_morf.Quad. ALDPAT

	Árvores	Não Árvores	
Árvores	154445	1563	99,00%
Não Árvores	514	32306	98,43%
	99,67%	95,39%	98,90%

Tabela 31 - SVM005_morf.Circ

	Árvores	Não Árvores	
Árvores	154099	1909	98,78%
Não Árvores	801	32019	97,56%
	99,48%	94,37%	98,56%

Tabela 32 - SVM010_morf.Circ

	Árvores	Não Árvores	
Árvores	154290	1718	98,90%
Não Árvores	721	32099	97,80%
	99,53%	94,92%	98,71%

Tabela 33 - SVM015_morf.Circ

	Árvores	Não Árvores	
Árvores	154327	1681	98,92%
Não Árvores	699	32121	97,87%
	99,55%	95,03%	98,74%

Tabela 34 - SVM020_morf.Circ

	Árvores	Não Árvores	
Árvores	154332	1676	98,93%
Não Árvores	662	32158	97,98%
	99,57%	95,05%	98,76%

Tabela 35 - SVM025_morf.Circ

	Árvores	Não Árvores	
Árvores	154295	1713	98,90%
Não Árvores	626	32194	98,09%
	99,60%	94,95%	98,76%

Tabela 36 - SVM030_morf.Circ

	Árvores	Não Árvores	
Árvores	154249	1759	98,87%
Não Árvores	598	32222	98,18%
	99,61%	94,82%	98,75%

Tabela 37 - SVM035_morf.Circ

	Árvores	Não Árvores	
Árvores	154260	1748	98,88%
Não Árvores	578	32242	98,24%
	99,63%	94,86%	98,77%

Tabela 38 - SVM040_morf.Circ

	Árvores	Não Árvores	
Árvores	154281	1727	98,89%
Não Árvores	573	32247	98,25%
	99,63%	94,92%	98,78%

Tabela 39 - SVM045_morf.Circ

	Árvores	Não Árvores	
Árvores	154285	1723	98,90%
Não Árvores	562	32258	98,29%
	99,64%	94,93%	98,79%

Tabela 40 - SVM050_morf.Circ

	Árvores	Não Árvores	
Árvores	154312	1696	98,91%
Não Árvores	561	32259	98,29%
	99,64%	95,01%	98,80%

Tabela 41 - SVM005_morf.Linear

	Árvore	Não Árvore	
Árvore	153041	2967	98,10%
Não Árvore	1144	31676	96,51%
	99,26%	91,44%	97,82%

Tabela 42 - SVM010_morf.Linear

	Árvore	Não Árvore	
Árvore	153098	2910	98,13%
Não Árvore	1044	31776	96,82%
	99,32%	91,61%	97,91%

Tabela 43 - SVM015_morf.Linear

	Árvore	Não Árvore	
Árvore	153391	2617	98,32%
Não Árvore	1035	31785	96,85%
	99,33%	92,39%	98,07%

Tabela 44 - SVM020_morf.Linear

	Árvore	Não Árvore	
Árvore	153401	2607	98,33%
Não Árvore	979	31841	97,02%
	99,37%	92,43%	98,10%

Tabela 45 - SVM025_morf.Linear

	Árvore	Não Árvore	
Árvore	153220	2788	98,21%
Não Árvore	884	31936	97,31%
	99,43%	91,97%	98,06%

Tabela 46 - SVM030_morf.Linear

	Árvore	Não Árvore	
Árvore	153073	2935	98,12%
Não Árvore	845	31975	97,43%
	99,45%	91,59%	98,00%

Tabela 47 - SVM035_morf.Linear

	Árvore	Não Árvore	
Árvore	153124	2884	98,15%
Não Árvore	838	31982	97,45%
	99,46%	91,73%	98,03%

Tabela 48 - SVM040_morf.Linear

	Árvore	Não Árvore	
Árvore	153171	2837	98,18%
Não Árvore	820	32000	97,50%
	99,47%	91,86%	98,06%

Tabela 49 - SVM045_morf.Linear

	Árvore	Não Árvore	
Árvore	153145	2863	98,16%
Não Árvore	806	32014	97,54%
	99,48%	91,79%	98,06%

Tabela 50 - SVM050_morf.Linear

	Árvore	Não Árvore	
Árvore	153166	2842	98,18%
Não Árvore	798	32022	97,57%
	99,48%	91,85%	98,07%

Tabela 51 - SVM005_morf.Quad.

	Árvore	Não Árvore	
Árvore	154126	1882	98,79%
Não Árvore	775	32045	97,64%
	99,50%	94,45%	98,59%

Tabela 52 - SVM010_morf.Quad.

	Árvore	Não Árvore	
Árvore	154164	1844	98,82%
Não Árvore	687	32133	97,91%
	99,56%	94,57%	98,66%

Tabela 53 - SVM015_morf.Quad.

	Árvore	Não Árvore	
Árvore	154227	1781	98,86%
Não Árvore	680	32140	97,93%
	99,56%	94,75%	98,70%

Tabela 54 - SVM020_morf.Quad.

	Árvore	Não Árvore	
Árvore	154257	1751	98,88%
Não Árvore	651	32169	98,02%
	99,58%	94,84%	98,73%

Tabela 55 - SVM025_morf.Quad.

	Árvore	Não Árvore	
Árvore	154228	1780	98,86%
Não Árvore	614	32206	98,13%
	99,60%	94,76%	98,73%

Tabela 56 - SVM030_morf.Quad.

	Árvore	Não Árvore	
Árvore	154163	1845	98,82%
Não Árvore	585	32235	98,22%
	99,62%	94,59%	98,71%

Tabela 57 - SVM035_morf.Quad.

	Árvore	Não Árvore	
Árvore	154176	1832	98,83%
Não Árvore	588	32232	98,21%
	99,62%	94,62%	98,72%

Tabela 58 - SVM040_morf.Quad.

	Árvore	Não Árvore	
Árvore	154222	1786	98,86%
Não Árvore	573	32247	98,25%
	99,63%	94,75%	98,75%

Tabela 59 - SVM045_morf.Quad.

	Árvore	Não Árvore	
Árvore	154235	1773	98,86%
Não Árvore	572	32248	98,26%
	99,63%	94,79%	98,76%

Tabela 60 - SVM050_morf.Quad.

	Árvore	Não Árvore	
Árvore	154262	1746	98,88%
Não Árvore	568	32252	98,27%
	99,63%	94,86%	98,77%

Tabela 61 - SVM005_TIN

	Árvores	Não Árvores	
Árvores	154128	1880	98,79%
Não Árvores	908	31912	97,23%
	99,41%	94,44%	98,52%

Tabela 62 - SVM010_TIN

	Árvores	Não Árvores	
Árvores	154219	1789	98,85%
Não Árvores	786	32034	97,61%
	99,49%	94,71%	98,64%

Tabela 63 - SVM015_TIN

	Árvores	Não Árvores	
Árvores	154321	1687	98,92%
Não Árvores	758	32062	97,69%
	99,51%	95,00%	98,71%

Tabela 64 - SVM020_TIN

	Árvores	Não Árvores	
Árvores	154356	1652	98,94%
Não Árvores	721	32099	97,80%
	99,54%	95,11%	98,74%

Tabela 65 - SVM025_TIN

	Árvores	Não Árvores	
Árvores	154305	1703	98,91%
Não Árvores	672	32148	97,95%
	99,57%	94,97%	98,74%

Tabela 66 - SVM030_TIN

	Árvores	Não Árvores	
Árvores	154225	1783	98,86%
Não Árvores	645	32175	98,03%
	99,58%	94,75%	98,71%

Tabela 67 - SVM035_TIN

	Árvores	Não Árvores	
Árvores	154284	1724	98,89%
Não Árvores	630	32190	98,08%
	99,59%	94,92%	98,75%

Tabela 68 - SVM040_TIN

	Árvores	Não Árvores	
Árvores	154270	1738	98,89%
Não Árvores	612	32208	98,14%
	99,60%	94,88%	98,76%

Tabela 69 - SVM045_TIN

	Árvores	Não Árvores	
Árvores	154257	1751	98,88%
Não Árvores	586	32234	98,21%
	99,62%	94,85%	98,76%

Tabela 70 - SVM050_TIN

	Árvores	Não Árvores	
Árvores	154277	1731	98,89%
Não Árvores	576	32244	98,24%
	99,63%	94,91%	98,78%

Tabela 71 - SVM005_ETEW

	Árvores	Não Árvores	
Árvores	153752	2256	98,55%
Não Árvores	1534	31286	95,33%
	99,01%	93,27%	97,99%

Tabela 72 - SVM010_ETEW

	Árvores	Não Árvores	
Árvores	153743	2265	98,55%
Não Árvores	1371	31449	95,82%
	99,12%	93,28%	98,07%

Tabela 73 - SVM015_ETEW

	Árvores	Não Árvores	
Árvores	154124	1884	98,79%
Não Árvores	1373	31447	95,82%
	99,12%	94,35%	98,28%

Tabela 74 - SVM020_ETEW

	Árvores	Não Árvores	
Árvores	154082	1926	98,77%
Não Árvores	1329	31491	95,95%
	99,14%	94,24%	98,28%

Tabela 75 - SVM025_ETEW

	Árvores	Não Árvores	
Árvores	154037	1971	98,74%
Não Árvores	1279	31541	96,10%
	99,18%	94,12%	98,28%

Tabela 76 - SVM030_ETEW

	Árvores	Não Árvores	
Árvores	154007	2001	98,72%
Não Árvores	1255	31565	96,18%
	99,19%	94,04%	98,28%

Tabela 77 - SVM035_ETEW

	Árvores	Não Árvores	
Árvores	153960	2048	98,69%
Não Árvores	1228	31592	96,26%
	99,21%	93,91%	98,27%

Tabela 78 - SVM040_ETEW

	Árvores	Não Árvores	
Árvores	154017	1991	98,72%
Não Árvores	1232	31588	96,25%
	99,21%	94,07%	98,29%

Tabela 79 - SVM045_ETEW

	Árvores	Não Árvores	
Árvores	154007	2001	98,72%
Não Árvores	1222	31598	96,28%
	99,21%	94,04%	98,29%

Tabela 80 - SVM050_ETEW

	Árvores	Não Árvores	
Árvores	154019	1989	98,73%
Não Árvores	1205	31615	96,33%
	99,22%	94,08%	98,31%

Tabela 81 - SVM005_Declividade

	Árvores	Não Árvores	
Árvores	154508	1500	99,04%
Não Árvores	980	31840	97,01%
	99,37%	95,50%	98,69%

Tabela 82 - SVM010_Declividade

	Árvores	Não Árvores	
Árvores	154427	1581	98,99%
Não Árvores	874	31946	97,34%
	99,44%	95,28%	98,70%

Tabela 83 - SVM015_Declividade

	Árvores	Não Árvores	
Árvores	154613	1395	99,11%
Não Árvores	827	31993	97,48%
	99,47%	95,82%	98,82%

Tabela 84 - SVM020_Declividade

	Árvores	Não Árvores	
Árvores	154677	1331	99,15%
Não Árvores	819	32001	97,50%
	99,47%	96,01%	98,86%

Tabela 85 - SVM025_Declividade

	Árvores	Não Árvores	
Árvores	154543	1465	99,06%
Não Árvores	764	32056	97,67%
	99,51%	95,63%	98,82%

Tabela 86 - SVM030_Declividade

	Árvores	Não Árvores	
Árvores	154342	1666	98,93%
Não Árvores	718	32102	97,81%
	99,54%	95,07%	98,74%

Tabela 87 - SVM035_Declividade

	Árvores	Não Árvores	
Árvores	154402	1606	98,97%
Não Árvores	707	32113	97,85%
	99,54%	95,24%	98,78%

Tabela 88 - SVM040_Declividade

	Árvores	Não Árvores	
Árvores	154456	1552	99,01%
Não Árvores	699	32121	97,87%
	99,55%	95,39%	98,81%

Tabela 89 - SVM045_Declividade

	Árvores	Não Árvores	
Árvores	154427	1581	98,99%
Não Árvores	668	32152	97,96%
	99,57%	95,31%	98,81%

Tabela 90 - SVM050_Declividade

	Árvores	Não Árvores	
Árvores	154460	1548	99,01%
Não Árvores	665	32155	97,97%
	99,57%	95,41%	98,83%

Tabela 91 - SVM005_Pirâmide

	Árvores	Não Árvores	
Árvores	154638	1370	99,12%
Não Árvores	975	31845	97,03%
	99,37%	95,88%	98,76%

Tabela 92 - SVM010_Pirâmide

	Árvores	Não Árvores	
Árvores	154536	1472	99,06%
Não Árvores	864	31956	97,37%
	99,44%	95,60%	98,76%

Tabela 93 - SVM015_Pirâmide

	Árvores	Não Árvores	
Árvores	154659	1349	99,14%
Não Árvores	822	31998	97,50%
	99,47%	95,95%	98,85%

Tabela 94 - SVM020_Pirâmide

	Árvores	Não Árvores	
Árvores	154671	1337	99,14%
Não Árvores	804	32016	97,55%
	99,48%	95,99%	98,87%

Tabela 95 - SVM025_Pirâmide

	Árvores	Não Árvores	
Árvores	154614	1394	99,11%
Não Árvores	764	32056	97,67%
	99,51%	95,83%	98,86%

Tabela 96 - SVM030_Pirâmide

	Árvores	Não Árvores	
Árvores	154443	1565	99,00%
Não Árvores	722	32098	97,80%
	99,53%	95,35%	98,79%

Tabela 97 - SVM035_Pirâmide

	Árvores	Não Árvores	
Árvores	154483	1525	99,02%
Não Árvores	721	32099	97,80%
	99,54%	95,46%	98,81%

Tabela 98 - SVM040_Pirâmide

	Árvores	Não Árvores	
Árvores	154521	1487	99,05%
Não Árvores	703	32117	97,86%
	99,55%	95,57%	98,84%

Tabela 99 - SVM045_Pirâmide

	Árvores	Não Árvores	
Árvores	154479	1529	99,02%
Não Árvores	688	32132	97,90%
	99,56%	95,46%	98,83%

Tabela 100 - SVM050_Pirâmide

	Árvores	Não Árvores	
Árvores	154545	1463	99,06%
Não Árvores	691	32129	97,89%
	99,55%	95,64%	98,86%

Tabela 101 - RNA005_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154598	1410	99,10%
Não Árvores	763	32057	97,68%
	99,51%	95,79%	98,85%

Tabela 102 - RNA010_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154682	1326	99,15%
Não Árvores	564	32256	98,28%
	99,64%	96,05%	99,00%

Tabela 103 - RNA015_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154672	1336	99,14%
Não Árvores	593	32227	98,19%
	99,62%	96,02%	98,98%

Tabela 104 - RNA020_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154643	1365	99,13%
Não Árvores	543	32277	98,35%
	99,65%	95,94%	98,99%

Tabela 105 - RNA025_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154603	1405	99,10%
Não Árvores	549	32271	98,33%
	99,65%	95,83%	98,97%

Tabela 106 - RNA030_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154610	1398	99,10%
Não Árvores	549	32271	98,33%
	99,65%	95,85%	98,97%

Tabela 107 - RNA035_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154590	1418	99,09%
Não Árvores	488	32332	98,51%
	99,69%	95,80%	98,99%

Tabela 108 - RNA040_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154616	1392	99,11%
Não Árvores	507	32313	98,46%
	99,67%	95,87%	98,99%

Tabela 109 - RNA045_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154729	1279	99,18%
Não Árvores	530	32290	98,39%
	99,66%	96,19%	99,04%

Tabela 110 - RNA050_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	154599	1409	99,10%
Não Árvores	479	32341	98,54%
	99,69%	95,83%	99,00%

Tabela 111 - RNA005_morf.Linear_ALDPAT

	Árvores	Não	
Árvores	152884	3124	98,00%
Não Árvores	578	32242	98,24%
	99,62%	91,17%	98,04%

Tabela 112 - RNA010_morf.Linear_ALDPAT

	Árvores	Não	
Árvores	153402	2606	98,33%
Não Árvores	504	32316	98,46%
	99,67%	92,54%	98,35%

Tabela 113 - RNA015_morf.Linear_ALDPAT

	Árvores	Não	
Árvores	153608	2400	98,46%
Não Árvores	483	32337	98,53%
	99,69%	93,09%	98,47%

Tabela 114 - RNA020_morf.Linear_ALDPAT

	Árvores	Não	
Árvores	153469	2539	98,37%
Não Árvores	465	32355	98,58%
	99,70%	92,72%	98,41%

Tabela 115 - RNA025_morf.Linear_ALDPAT

	Árvores	Não	
Árvores	153640	2368	98,48%
Não Árvores	501	32319	98,47%
	99,67%	93,17%	98,48%

Tabela 116 - RNA030_morf.Linear_ALDPAT

	Árvores	Não	
Árvores	153703	2305	98,52%
Não Árvores	459	32361	98,60%
	99,70%	93,35%	98,54%

Tabela 117 - RNA035_morf.Linear_ALDPAT

	Árvores	Não	
Árvores	153457	2551	98,36%
Não Árvores	463	32357	98,59%
	99,70%	92,69%	98,40%

Tabela 118 - RNA040_morf.Linear_ALDPAT

	Árvores	Não	
Árvores	153802	2206	98,59%
Não Árvores	397	32423	98,79%
	99,74%	93,63%	98,62%

Tabela 119 - RNA045_morf.Linear_ALDPAT

	Árvores	Não	
Árvores	153627	2381	98,47%
Não Árvores	386	32434	98,82%
	99,75%	93,16%	98,53%

Tabela 120 - RNA050_morf.Linear_ALDPAT

	Árvores	Não	
Árvores	153627	2381	98,47%
Não Árvores	396	32424	98,79%
	99,74%	93,16%	98,53%

Tabela 121 - RNA005_morf.Quad._ALDPAT

	Árvores	Não	
Árvores	153936	2072	98,67%
Não Árvores	587	32233	98,21%
	99,62%	93,96%	98,59%

Tabela 122 - RNA010_morf.Quad._ALDPAT

	Árvores	Não	
Árvores	154301	1707	98,91%
Não Árvores	591	32229	98,20%
	99,62%	94,97%	98,78%

Tabela 123 - RNA015_morf.Quad._ALDPAT

	Árvores	Não	
Árvores	154385	1623	98,96%
Não Árvores	556	32264	98,31%
	99,64%	95,21%	98,85%

Tabela 124 - RNA020_morf.Quad._ALDPAT

	Árvores	Não	
Árvores	154372	1636	98,95%
Não Árvores	508	32312	98,45%
	99,67%	95,18%	98,86%

Tabela 125 - RNA025_morf.Quad._ALDPAT

	Árvores	Não	
Árvores	154448	1560	99,00%
Não Árvores	497	32323	98,49%
	99,68%	95,40%	98,91%

Tabela 126 - RNA030_morf.Quad._ALDPAT

	Árvores	Não	
Árvores	154419	1589	98,98%
Não Árvores	413	32407	98,74%
	99,73%	95,33%	98,94%

Tabela 127 - RNA035_morf.Quad._ALDPAT

	Árvores	Não	
Árvores	154389	1619	98,96%
Não Árvores	448	32372	98,63%
	99,71%	95,24%	98,91%

Tabela 128 - RNA040_morf.Quad._ALDPAT

	Árvores	Não	
Árvores	154395	1613	98,97%
Não Árvores	519	32301	98,42%
	99,66%	95,24%	98,87%

Tabela 129 - RNA045_morf.Quad._ALDPAT

	Árvores	Não	
Árvores	154359	1649	98,94%
Não Árvores	388	32432	98,82%
	99,75%	95,16%	98,92%

Tabela 130 - RNA050_morf.Quad._ALDPAT

	Árvores	Não	
Árvores	154358	1650	98,94%
Não Árvores	402	32418	98,78%
	99,74%	95,16%	98,91%

Tabela 131 - RNA005_morf.Circ

	Árvores	Não	
Árvores	153798	2210	98,58%
Não Árvores	773	32047	97,64%
	99,50%	93,55%	98,42%

Tabela 132 - RNA010_morf.Circ

	Árvores	Não	
Árvores	154080	1928	98,76%
Não Árvores	502	32318	98,47%
	99,68%	94,37%	98,71%

Tabela 133 - RNA015_morf.Circ

	Árvores	Não	
Árvores	154008	2000	98,72%
Não Árvores	665	32155	97,97%
	99,57%	94,14%	98,59%

Tabela 134 - RNA020_morf.Circ

	Árvores	Não	
Árvores	153975	2033	98,70%
Não Árvores	701	32119	97,86%
	99,55%	94,05%	98,55%

Tabela 135 - RNA025_morf.Circ

	Árvores	Não	
Árvores	154260	1748	98,88%
Não Árvores	499	32321	98,48%
	99,68%	94,87%	98,81%

Tabela 136 - RNA030_morf.Circ

	Árvores	Não	
Árvores	154065	1943	98,75%
Não Árvores	472	32348	98,56%
	99,69%	94,33%	98,72%

Tabela 137 - RNA035_morf.Circ

	Árvores	Não	
Árvores	154141	1867	98,80%
Não Árvores	460	32360	98,60%
	99,70%	94,55%	98,77%

Tabela 138 - RNA040_morf.Circ

	Árvores	Não	
Árvores	153998	2010	98,71%
Não Árvores	442	32378	98,65%
	99,71%	94,15%	98,70%

Tabela 139 - RNA045_morf.Circ

	Árvores	Não	
Árvores	154260	1748	98,88%
Não Árvores	427	32393	98,70%
	99,72%	94,88%	98,85%

Tabela 140 - RNA050_morf.Circ

	Árvores	Não	
Árvores	154306	1702	98,91%
Não Árvores	433	32387	98,68%
	99,72%	95,01%	98,87%

Tabela 141 - RNA005_morf.Linear

	Árvores	Não	
Árvores	152734	3274	97,90%
Não Árvores	1141	31679	96,52%
	99,26%	90,63%	97,66%

Tabela 142 - RNA010_morf.Linear

	Árvores	Não	
Árvores	152061	3947	97,47%
Não Árvores	978	31842	97,02%
	99,36%	88,97%	97,39%

Tabela 143 - RNA015_morf.Linear

	Árvores	Não	
Árvores	152806	3202	97,95%
Não Árvores	948	31872	97,11%
	99,38%	90,87%	97,80%

Tabela 144 - RNA020_morf.Linear

	Árvores	Não	
Árvores	152976	3032	98,06%
Não Árvores	860	31960	97,38%
	99,44%	91,34%	97,94%

Tabela 145 - RNA025_morf.Linear

	Árvores	Não	
Árvores	153027	2981	98,09%
Não Árvores	886	31934	97,30%
	99,42%	91,46%	97,95%

Tabela 146 - RNA030_morf.Linear

	Árvores	Não	
Árvores	152950	3058	98,04%
Não Árvores	947	31873	97,11%
	99,38%	91,25%	97,88%

Tabela 147 - RNA035_morf.Linear

	Árvores	Não	
Árvores	153317	2691	98,28%
Não Árvores	859	31961	97,38%
	99,44%	92,23%	98,12%

Tabela 148 - RNA040_morf.Linear

	Árvores	Não	
Árvores	153295	2713	98,26%
Não Árvores	872	31948	97,34%
	99,43%	92,17%	98,10%

Tabela 149 - RNA045_morf.Linear

	Árvores	Não	
Árvores	153009	2999	98,08%
Não Árvores	805	32015	97,55%
	99,48%	91,43%	97,99%

Tabela 150 - RNA050_morf.Linear

	Árvores	Não	
Árvores	153235	2773	98,22%
Não Árvores	754	32066	97,70%
	99,51%	92,04%	98,13%

Tabela 151 - RNA005_morf.Quad.

	Árvores	Não	
Árvores	153493	2515	98,39%
Não Árvores	639	32181	98,05%
	99,59%	92,75%	98,33%

Tabela 152 - RNA010_morf.Quad.

	Árvores	Não	
Árvores	153970	2038	98,69%
Não Árvores	592	32228	98,20%
	99,62%	94,05%	98,61%

Tabela 153 - RNA015_morf.Quad.

	Árvores	Não	
Árvores	154133	1875	98,80%
Não Árvores	663	32157	97,98%
	99,57%	94,49%	98,66%

Tabela 154 - RNA020_morf.Quad.

	Árvores	Não	
Árvores	154537	1471	99,06%
Não Árvores	714	32106	97,82%
	99,54%	95,62%	98,84%

Tabela 155 - RNA025_morf.Quad.

	Árvores	Não	
Árvores	154215	1793	98,85%
Não Árvores	519	32301	98,42%
	99,66%	94,74%	98,78%

Tabela 156 - RNA030_morf.Quad.

	Árvores	Não	
Árvores	154382	1626	98,96%
Não Árvores	598	32222	98,18%
	99,61%	95,20%	98,82%

Tabela 157 - RNA035_morf.Quad.

	Árvores	Não	
Árvores	154506	1502	99,04%
Não Árvores	601	32219	98,17%
	99,61%	95,55%	98,89%

Tabela 158 - RNA040_morf.Quad.

	Árvores	Não	
Árvores	154228	1780	98,86%
Não Árvores	556	32264	98,31%
	99,64%	94,77%	98,76%

Tabela 159 - RNA045_morf.Quad.

	Árvores	Não	
Árvores	154188	1820	98,83%
Não Árvores	634	32186	98,07%
	99,59%	94,65%	98,70%

Tabela 160 - RNA050_morf.Quad.

	Árvores	Não	
Árvores	154328	1680	98,92%
Não Árvores	543	32277	98,35%
	99,65%	95,05%	98,82%

Tabela 161 - RNA005_TIN

	Árvores	Não	
Árvores	153467	2541	98,37%
Não Árvores	716	32104	97,82%
	99,54%	92,67%	98,28%

Tabela 162 - RNA010_TIN

	Árvores	Não	
Árvores	153781	2227	98,57%
Não Árvores	642	32178	98,04%
	99,58%	93,53%	98,48%

Tabela 163 - RNA015_TIN

	Árvores	Não	
Árvores	153935	2073	98,67%
Não Árvores	572	32248	98,26%
	99,63%	93,96%	98,60%

Tabela 164 - RNA020_TIN

	Árvores	Não	
Árvores	153806	2202	98,59%
Não Árvores	509	32311	98,45%
	99,67%	93,62%	98,56%

Tabela 165 - RNA025_TIN

	Árvores	Não	
Árvores	153962	2046	98,69%
Não Árvores	513	32307	98,44%
	99,67%	94,04%	98,64%

Tabela 166 - RNA030_TIN

	Árvores	Não	
Árvores	154161	1847	98,82%
Não Árvores	512	32308	98,44%
	99,67%	94,59%	98,75%

Tabela 167 - RNA035_TIN

	Árvores	Não	
Árvores	154224	1784	98,86%
Não Árvores	494	32326	98,49%
	99,68%	94,77%	98,79%

Tabela 168 - RNA040_TIN

	Árvores	Não	
Árvores	154212	1796	98,85%
Não Árvores	459	32361	98,60%
	99,70%	94,74%	98,81%

Tabela 169 - RNA045_TIN

	Árvores	Não	
Árvores	153762	2246	98,56%
Não Árvores	487	32333	98,52%
	99,68%	93,50%	98,55%

Tabela 170 - RNA050_TIN

	Árvores	Não	
Árvores	153985	2023	98,70%
Não Árvores	468	32352	98,57%
	99,70%	94,11%	98,68%

Tabela 171 - RNA005_ETEW

	Árvores	Não	
Árvores	153122	2886	98,15%
Não Árvores	1354	31466	95,87%
	99,12%	91,60%	97,75%

Tabela 172 - RNA010_ETEW

	Árvores	Não	
Árvores	152315	3693	97,63%
Não Árvores	1444	31376	95,60%
	99,06%	89,47%	97,28%

Tabela 173 - RNA015_ETEW

	Árvores	Não	
Árvores	153077	2931	98,12%
Não Árvores	1267	31553	96,14%
	99,18%	91,50%	97,78%

Tabela 174 - RNA020_ETEW

	Árvores	Não	
Árvores	153171	2837	98,18%
Não Árvores	1210	31610	96,31%
	99,22%	91,76%	97,86%

Tabela 175 - RNA025_ETEW

	Árvores	Não	
Árvores	153361	2647	98,30%
Não Árvores	1182	31638	96,40%
	99,24%	92,28%	97,97%

Tabela 176 - RNA030_ETEW

	Árvores	Não	
Árvores	153289	2719	98,26%
Não Árvores	1160	31660	96,47%
	99,25%	92,09%	97,95%

Tabela 177 - RNA035_ETEW

	Árvores	Não	
Árvores	152942	3066	98,03%
Não Árvores	1068	31752	96,75%
	99,31%	91,19%	97,81%

Tabela 178 - RNA040_ETEW

	Árvores	Não	
Árvores	153189	2819	98,19%
Não Árvores	1189	31631	96,38%
	99,23%	91,82%	97,88%

Tabela 179 - RNA045_ETEW

	Árvores	Não	
Árvores	153357	2651	98,30%
Não Árvores	1124	31696	96,58%
	99,27%	92,28%	98,00%

Tabela 180 - RNA050_ETEW

	Árvores	Não	
Árvores	153245	2763	98,23%
Não Árvores	989	31831	96,99%
	99,36%	92,01%	98,01%

Tabela 181 - RNA005_Declividade

	Árvores	Não	
Árvores	154461	1547	99,01%
Não Árvores	1035	31785	96,85%
	99,33%	95,36%	98,63%

Tabela 182 - RNA010_Declividade

	Árvores	Não	
Árvores	154162	1846	98,82%
Não Árvores	768	32052	97,66%
	99,50%	94,55%	98,62%

Tabela 183 - RNA015_Declividade

	Árvores	Não	
Árvores	154047	1961	98,74%
Não Árvores	810	32010	97,53%
	99,48%	94,23%	98,53%

Tabela 184 - RNA020_Declividade

	Árvores	Não	
Árvores	154342	1666	98,93%
Não Árvores	757	32063	97,69%
	99,51%	95,06%	98,72%

Tabela 185 - RNA025_Declividade

	Árvores	Não	
Árvores	153411	2597	98,34%
Não Árvores	677	32143	97,94%
	99,56%	92,52%	98,27%

Tabela 186 - RNA030_Declividade

	Árvores	Não	
Árvores	154196	1812	98,84%
Não Árvores	615	32205	98,13%
	99,60%	94,67%	98,71%

Tabela 187 - RNA035_Declividade

	Árvores	Não	
Árvores	154044	1964	98,74%
Não Árvores	587	32233	98,21%
	99,62%	94,26%	98,65%

Tabela 188 - RNA040_Declividade

	Árvores	Não	
Árvores	154445	1563	99,00%
Não Árvores	641	32179	98,05%
	99,59%	95,37%	98,83%

Tabela 189 - RNA045_Declividade

	Árvores	Não	
Árvores	154331	1677	98,93%
Não Árvores	583	32237	98,22%
	99,62%	95,06%	98,80%

Tabela 190 - RNA050_Declividade

	Árvores	Não	
Árvores	154431	1577	98,99%
Não Árvores	550	32270	98,32%
	99,65%	95,34%	98,87%

Tabela 191 - RNA005_Pirâmide

	Árvores	Não	
Árvores	154305	1703	98,91%
Não Árvores	832	31988	97,46%
	99,46%	94,95%	98,66%

Tabela 192 - RNA010_Pirâmide

	Árvores	Não	
Árvores	154089	1919	98,77%
Não Árvores	761	32059	97,68%
	99,51%	94,35%	98,58%

Tabela 193 - RNA015_Pirâmide

	Árvores	Não	
Árvores	154682	1326	99,15%
Não Árvores	730	32090	97,78%
	99,53%	96,03%	98,91%

Tabela 194 - RNA020_Pirâmide

	Árvores	Não	
Árvores	154438	1570	98,99%
Não Árvores	711	32109	97,83%
	99,54%	95,34%	98,79%

Tabela 195 - RNA025_Pirâmide

	Árvores	Não	
Árvores	154544	1464	99,06%
Não Árvores	611	32209	98,14%
	99,61%	95,65%	98,90%

Tabela 196 - RNA030_Pirâmide

	Árvores	Não	
Árvores	154654	1354	99,13%
Não Árvores	668	32152	97,96%
	99,57%	95,96%	98,93%

Tabela 197 - RNA035_Pirâmide

	Árvores	Não	
Árvores	154374	1634	98,95%
Não Árvores	583	32237	98,22%
	99,62%	95,18%	98,83%

Tabela 198 - RNA040_Pirâmide

	Árvores	Não	
Árvores	154423	1585	98,98%
Não Árvores	588	32232	98,21%
	99,62%	95,31%	98,85%

Tabela 199 - RNA045_Pirâmide

	Árvores	Não	
Árvores	154640	1368	99,12%
Não Árvores	649	32171	98,02%
	99,58%	95,92%	98,93%

Tabela 200 - RNA050_Pirâmide

	Árvores	Não	
Árvores	154491	1517	99,03%
Não Árvores	613	32207	98,13%
	99,60%	95,50%	98,87%

APÊNDICE H - Matriz de Confusão da Classificação com *Support Vector Machine* e Redes Neurais Artificiais, para treinamento de 5%, 10%, 15%, 20%, 25%, 30%, 35%, 40%, 45%, 50%, e os métodos de filtragem, para a Área da Água Verde – Rebouças, Curitiba - PR

Tabela 1 - SVM005_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212277	4180	98,07%
Não Árvores	1926	71376	97,37%
	99,10%	94,47%	97,89%

Tabela 2 - SVM010_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212397	4060	98,12%
Não Árvores	1855	71447	97,47%
	99,13%	94,62%	97,96%

Tabela 3 - SVM015_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212382	4075	98,12%
Não Árvores	1807	71495	97,53%
	99,16%	94,61%	97,97%

Tabela 4 - SVM020_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212358	4099	98,11%
Não Árvores	1735	71567	97,63%
	99,19%	94,58%	97,99%

Tabela 5 - SVM025_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212373	4084	98,11%
Não Árvores	1724	71578	97,65%
	99,19%	94,60%	98,00%

Tabela 6 - SVM030_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212323	4134	98,09%
Não Árvores	1690	71612	97,69%
	99,21%	94,54%	97,99%

Tabela 7 - SVM035_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212318	4139	98,09%
Não Árvores	1669	71633	97,72%
	99,22%	94,54%	98,00%

Tabela 8 - SVM040_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212330	4127	98,09%
Não Árvores	1665	71637	97,73%
	99,22%	94,55%	98,00%

Tabela 9 - SVM045_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212372	4085	98,11%
Não Árvores	1669	71633	97,72%
	99,22%	94,60%	98,01%

Tabela 10 - SVM050_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212417	4040	98,13%
Não Árvores	1675	71627	97,71%
	99,22%	94,66%	98,03%

Tabela 11 - SVM005_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212297	4160	98,08%
Não Árvores	1895	71407	97,41%
	99,12%	94,49%	97,91%

Tabela 12 - SVM010_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212479	3978	98,16%
Não Árvores	1852	71450	97,47%
	99,14%	94,73%	97,99%

Tabela 13 - SVM015_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212493	3964	98,17%
Não Árvores	1781	71521	97,57%
	99,17%	94,75%	98,02%

Tabela 14 - SVM020_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212461	3996	98,15%
Não Árvores	1737	71565	97,63%
	99,19%	94,71%	98,02%

Tabela 15 - SVM025_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212444	4013	98,15%
Não Árvores	1701	71601	97,68%
	99,21%	94,69%	98,03%

Tabela 16 - SVM030_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212426	4031	98,14%
Não Árvores	1681	71621	97,71%
	99,21%	94,67%	98,03%

Tabela 17 - SVM035_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212412	4045	98,13%
Não Árvores	1672	71630	97,72%
	99,22%	94,65%	98,03%

Tabela 18 - SVM040_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212413	4044	98,13%
Não Árvores	1661	71641	97,73%
	99,22%	94,66%	98,03%

Tabela 19 - SVM045_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212465	3992	98,16%
Não Árvores	1658	71644	97,74%
	99,23%	94,72%	98,05%

Tabela 20 - SVM050_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212532	3925	98,19%
Não Árvores	1677	71625	97,71%
	99,22%	94,80%	98,07%

Tabela 21 - SVM005_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212122	4335	98,00%
Não Árvores	1951	71351	97,34%
	99,09%	94,27%	97,83%

Tabela 22 - SVM010_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212379	4078	98,12%
Não Árvores	1934	71368	97,36%
	99,10%	94,59%	97,93%

Tabela 23 - SVM015_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212342	4115	98,10%
Não Árvores	1853	71449	97,47%
	99,13%	94,55%	97,94%

Tabela 24 - SVM020_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212296	4161	98,08%
Não Árvores	1782	71520	97,57%
	99,17%	94,50%	97,95%

Tabela 25 - SVM025_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212278	4179	98,07%
Não Árvores	1760	71542	97,60%
	99,18%	94,48%	97,95%

Tabela 26 - SVM030_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212249	4208	98,06%
Não Árvores	1743	71559	97,62%
	99,19%	94,45%	97,95%

Tabela 27 - SVM035_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212270	4187	98,07%
Não Árvores	1733	71569	97,64%
	99,19%	94,47%	97,96%

Tabela 28 - SVM040_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212283	4174	98,07%
Não Árvores	1715	71587	97,66%
	99,20%	94,49%	97,97%

Tabela 29 - SVM045_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212286	4171	98,07%
Não Árvores	1709	71593	97,67%
	99,20%	94,49%	97,97%

Tabela 30 - SVM050_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212328	4129	98,09%
Não Árvores	1716	71586	97,66%
	99,20%	94,55%	97,98%

Tabela 31 - SVM005_morf.Circ

	Árvores	Não Árvores	
Árvores	212337	4120	98,10%
Não Árvores	1851	71451	97,47%
	99,14%	94,55%	97,94%

Tabela 32 - SVM010_morf.Circ

	Árvores	Não Árvores	
Árvores	212528	3929	98,18%
Não Árvores	1885	71417	97,43%
	99,12%	94,79%	97,99%

Tabela 33 - SVM015_morf.Circ

	Árvores	Não Árvores	
Árvores	212430	4027	98,14%
Não Árvores	1773	71529	97,58%
	99,17%	94,67%	98,00%

Tabela 34 - SVM020_morf.Circ

	Árvores	Não Árvores	
Árvores	212372	4085	98,11%
Não Árvores	1742	71560	97,62%
	99,19%	94,60%	97,99%

Tabela 35 - SVM025_morf.Circ

	Árvores	Não Árvores	
Árvores	212421	4036	98,14%
Não Árvores	1723	71579	97,65%
	99,20%	94,66%	98,01%

Tabela 36 - SVM030_morf.Circ

	Árvores	Não Árvores	
Árvores	212420	4037	98,13%
Não Árvores	1697	71605	97,68%
	99,21%	94,66%	98,02%

Tabela 37 - SVM035_morf.Circ

	Árvores	Não Árvores	
Árvores	212403	4054	98,13%
Não Árvores	1686	71616	97,70%
	99,21%	94,64%	98,02%

Tabela 38 - SVM040_morf.Circ

	Árvores	Não Árvores	
Árvores	212414	4043	98,13%
Não Árvores	1690	71612	97,69%
	99,21%	94,66%	98,02%

Tabela 39 - SVM045_morf.Circ

	Árvores	Não Árvores	
Árvores	212428	4029	98,14%
Não Árvores	1684	71618	97,70%
	99,21%	94,67%	98,03%

Tabela 40 - SVM050_morf.Circ

	Árvores	Não Árvores	
Árvores	212442	4015	98,15%
Não Árvores	1686	71616	97,70%
	99,21%	94,69%	98,03%

Tabela 41 - SVM005_morf.Linear

	Árvores	Não Árvores	
Árvores	212269	4188	98,07%
Não Árvores	1962	71340	97,32%
	99,08%	94,46%	97,88%

Tabela 42 - SVM010_morf.Linear

	Árvores	Não Árvores	
Árvores	212425	4032	98,14%
Não Árvores	1934	71368	97,36%
	99,10%	94,65%	97,94%

Tabela 43 - SVM015_morf.Linear

	Árvores	Não Árvores	
Árvores	212446	4011	98,15%
Não Árvores	1878	71424	97,44%
	99,12%	94,68%	97,97%

Tabela 44 - SVM020_morf.Linear

	Árvores	Não Árvores	
Árvores	212368	4089	98,11%
Não Árvores	1831	71471	97,50%
	99,15%	94,59%	97,96%

Tabela 45 - SVM025_morf.Linear

	Árvores	Não Árvores	
Árvores	212410	4047	98,13%
Não Árvores	1821	71481	97,52%
	99,15%	94,64%	97,97%

Tabela 46 - SVM030_morf.Linear

	Árvores	Não Árvores	
Árvores	212416	4041	98,13%
Não Árvores	1824	71478	97,51%
	99,15%	94,65%	97,98%

Tabela 47 - SVM035_morf.Linear

	Árvores	Não Árvores	
Árvores	212394	4063	98,12%
Não Árvores	1798	71504	97,55%
	99,16%	94,62%	97,98%

Tabela 48 - SVM040_morf.Linear

	Árvores	Não Árvores	
Árvores	212396	4061	98,12%
Não Árvores	1779	71523	97,57%
	99,17%	94,63%	97,98%

Tabela 49 - SVM045_morf.Linear

	Árvores	Não Árvores	
Árvores	212442	4015	98,15%
Não Árvores	1778	71524	97,57%
	99,17%	94,68%	98,00%

Tabela 50 - SVM050_morf.Linear

	Árvores	Não Árvores	
Árvores	212447	4010	98,15%
Não Árvores	1782	71520	97,57%
	99,17%	94,69%	98,00%

Tabela 51 - SVM005_morf.Quad.

	Árvores	Não Árvores	
Árvores	212214	4243	98,04%
Não Árvores	1869	71433	97,45%
	99,13%	94,39%	97,89%

Tabela 52 - SVM010_morf.Quad.

	Árvores	Não Árvores	
Árvores	212402	4055	98,13%
Não Árvores	1858	71444	97,47%
	99,13%	94,63%	97,96%

Tabela 53 - SVM015_morf.Quad.

	Árvores	Não Árvores	
Árvores	212398	4059	98,12%
Não Árvores	1794	71508	97,55%
	99,16%	94,63%	97,98%

Tabela 54 - SVM020_morf.Quad.

	Árvores	Não Árvores	
Árvores	212321	4136	98,09%
Não Árvores	1749	71553	97,61%
	99,18%	94,54%	97,97%

Tabela 55 - SVM025_morf.Quad.

	Árvores	Não Árvores	
Árvores	212350	4107	98,10%
Não Árvores	1749	71553	97,61%
	99,18%	94,57%	97,98%

Tabela 56 - SVM030_morf.Quad.

	Árvores	Não Árvores	
Árvores	212328	4129	98,09%
Não Árvores	1730	71572	97,64%
	99,19%	94,55%	97,98%

Tabela 57 - SVM035_morf.Quad.

	Árvores	Não Árvores	
Árvores	212331	4126	98,09%
Não Árvores	1718	71584	97,66%
	99,20%	94,55%	97,98%

Tabela 58 - SVM040_morf.Quad.

	Árvores	Não Árvores	
Árvores	212354	4103	98,10%
Não Árvores	1706	71596	97,67%
	99,20%	94,58%	98,00%

Tabela 59 - SVM045_morf.Quad.

	Árvores	Não Árvores	
Árvores	212399	4058	98,13%
Não Árvores	1716	71586	97,66%
	99,20%	94,64%	98,01%

Tabela 60 - SVM050_morf.Quad.

	Árvores	Não Árvores	
Árvores	212426	4031	98,14%
Não Árvores	1714	71588	97,66%
	99,20%	94,67%	98,02%

Tabela 61 - SVM005_TIN

	Árvores	Não Árvores	
Árvores	212433	4024	98,14%
Não Árvores	1803	71499	97,54%
	99,16%	94,67%	97,99%

Tabela 62 - SVM010_TIN

	Árvores	Não Árvores	
Árvores	212628	3829	98,23%
Não Árvores	1803	71499	97,54%
	99,16%	94,92%	98,06%

Tabela 63 - SVM015_TIN

	Árvores	Não Árvores	
Árvores	212663	3794	98,25%
Não Árvores	1768	71534	97,59%
	99,18%	94,96%	98,08%

Tabela 64 - SVM020_TIN

	Árvores	Não Árvores	
Árvores	212631	3826	98,23%
Não Árvores	1717	71585	97,66%
	99,20%	94,93%	98,09%

Tabela 65 - SVM025_TIN

	Árvores	Não Árvores	
Árvores	212669	3788	98,25%
Não Árvores	1717	71585	97,66%
	99,20%	94,97%	98,10%

Tabela 66 - SVM030_TIN

	Árvores	Não Árvores	
Árvores	212660	3797	98,25%
Não Árvores	1691	71611	97,69%
	99,21%	94,96%	98,11%

Tabela 67 - SVM035_TIN

	Árvores	Não Árvores	
Árvores	212672	3785	98,25%
Não Árvores	1673	71629	97,72%
	99,22%	94,98%	98,12%

Tabela 68 - SVM040_TIN

	Árvores	Não Árvores	
Árvores	212740	3717	98,28%
Não Árvores	1689	71613	97,70%
	99,21%	95,07%	98,13%

Tabela 69 - SVM045_TIN

	Árvores	Não Árvores	
Árvores	212789	3668	98,31%
Não Árvores	1698	71604	97,68%
	99,21%	95,13%	98,15%

Tabela 70 - SVM050_TIN

	Árvores	Não Árvores	
Árvores	212806	3651	98,31%
Não Árvores	1692	71610	97,69%
	99,21%	95,15%	98,16%

Tabela 71 - SVM005_ETEW

	Árvores	Não Árvores	
Árvores	212157	4300	98,01%
Não Árvores	1878	71424	97,44%
	99,12%	94,32%	97,87%

Tabela 72 - SVM010_ETEW

	Árvores	Não Árvores	
Árvores	212328	4129	98,09%
Não Árvores	1863	71439	97,46%
	99,13%	94,54%	97,93%

Tabela 73 - SVM015_ETEW

	Árvores	Não Árvores	
Árvores	212340	4117	98,10%
Não Árvores	1785	71517	97,56%
	99,17%	94,56%	97,96%

Tabela 74 - SVM020_ETEW

	Árvores	Não Árvores	
Árvores	212277	4180	98,07%
Não Árvores	1716	71586	97,66%
	99,20%	94,48%	97,97%

Tabela 75 - SVM025_ETEW

	Árvores	Não Árvores	
Árvores	212278	4179	98,07%
Não Árvores	1689	71613	97,70%
	99,21%	94,49%	97,97%

Tabela 76 - SVM030_ETEW

	Árvores	Não Árvores	
Árvores	212288	4169	98,07%
Não Árvores	1686	71616	97,70%
	99,21%	94,50%	97,98%

Tabela 77 - SVM035_ETEW

	Árvores	Não Árvores	
Árvores	212295	4162	98,08%
Não Árvores	1676	71626	97,71%
	99,22%	94,51%	97,99%

Tabela 78 - SVM040_ETEW

	Árvores	Não Árvores	
Árvores	212311	4146	98,08%
Não Árvores	1663	71639	97,73%
	99,22%	94,53%	98,00%

Tabela 79 - SVM045_ETEW

	Árvores	Não Árvores	
Árvores	212327	4130	98,09%
Não Árvores	1664	71638	97,73%
	99,22%	94,55%	98,00%

Tabela 80 - SVM050_ETEW

	Árvores	Não Árvores	
Árvores	212379	4078	98,12%
Não Árvores	1683	71619	97,70%
	99,21%	94,61%	98,01%

Tabela 81 - SVM005_Declividade

	Árvores	Não Árvores	
Árvores	212233	4224	98,05%
Não Árvores	1924	71378	97,38%
	99,10%	94,41%	97,88%

Tabela 82 - SVM010_Declividade

	Árvores	Não Árvores	
Árvores	212473	3984	98,16%
Não Árvores	1873	71429	97,44%
	99,13%	94,72%	97,98%

Tabela 83 - SVM015_Declividade

	Árvores	Não Árvores	
Árvores	212511	3946	98,18%
Não Árvores	1813	71489	97,53%
	99,15%	94,77%	98,01%

Tabela 84 - SVM020_Declividade

	Árvores	Não Árvores	
Árvores	212439	4018	98,14%
Não Árvores	1756	71546	97,60%
	99,18%	94,68%	98,01%

Tabela 85 - SVM025_Declividade

	Árvores	Não Árvores	
Árvores	212466	3991	98,16%
Não Árvores	1751	71551	97,61%
	99,18%	94,72%	98,02%

Tabela 86 - SVM030_Declividade

	Árvores	Não Árvores	
Árvores	212453	4004	98,15%
Não Árvores	1731	71571	97,64%
	99,19%	94,70%	98,02%

Tabela 87 - SVM035_Declividade

	Árvores	Não Árvores	
Árvores	212455	4002	98,15%
Não Árvores	1707	71595	97,67%
	99,20%	94,71%	98,03%

Tabela 88 - SVM040_Declividade

	Árvores	Não Árvores	
Árvores	212459	3998	98,15%
Não Árvores	1684	71618	97,70%
	99,21%	94,71%	98,04%

Tabela 89 - SVM045_Declividade

	Árvores	Não Árvores	
Árvores	212480	3977	98,16%
Não Árvores	1695	71607	97,69%
	99,21%	94,74%	98,04%

Tabela 90 - SVM050_Declividade

	Árvores	Não Árvores	
Árvores	212501	3956	98,17%
Não Árvores	1700	71602	97,68%
	99,21%	94,76%	98,05%

Tabela 91 - SVM005_Pirâmide

	Árvores	Não Árvores	
Árvores	181164	35293	83,70%
Não Árvores	584	72718	99,20%
	99,68%	67,32%	87,62%

Tabela 92 - SVM010_Pirâmide

	Árvores	Não Árvores	
Árvores	182483	33974	84,30%
Não Árvores	650	72652	99,11%
	99,65%	68,14%	88,05%

Tabela 93 - SVM015_Pirâmide

	Árvores	Não Árvores	
Árvores	184510	31947	85,24%
Não Árvores	800	72502	98,91%
	99,57%	69,41%	88,70%

Tabela 94 - SVM020_Pirâmide

	Árvores	Não Árvores	
Árvores	183845	32612	84,93%
Não Árvores	805	72497	98,90%
	99,56%	68,97%	88,47%

Tabela 95 - SVM025_Pirâmide

	Árvores	Não Árvores	
Árvores	184625	31832	85,29%
Não Árvores	872	72430	98,81%
	99,53%	69,47%	88,71%

Tabela 96 - SVM030_Pirâmide

	Árvores	Não Árvores	
Árvores	179919	36538	83,12%
Não Árvores	704	72598	99,04%
	99,61%	66,52%	87,15%

Tabela 97 - SVM035_Pirâmide

	Árvores	Não Árvores	
Árvores	172511	43946	79,70%
Não Árvores	843	72459	98,85%
	99,51%	62,25%	84,54%

Tabela 98 - SVM040_Pirâmide

	Árvores	Não Árvores	
Árvores	181538	34919	83,87%
Não Árvores	819	72483	98,88%
	99,55%	67,49%	87,67%

Tabela 99 - SVM045_Pirâmide

	Árvores	Não Árvores	
Árvores	184166	32291	85,08%
Não Árvores	786	72516	98,93%
	99,58%	69,19%	88,58%

Tabela 100 - SVM050_Pirâmide

	Árvores	Não Árvores	
Árvores	187827	28630	86,77%
Não Árvores	1120	72182	98,47%
	99,41%	71,60%	89,73%

Tabela 101 - RNA005_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	211643	4814	97,78%
Não Árvores	1660	71642	97,74%
	99,22%	93,70%	97,77%

Tabela 102 - RNA010_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212207	4250	98,04%
Não Árvores	1708	71594	97,67%
	99,20%	94,40%	97,94%

Tabela 103 - RNA015_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212126	4331	98,00%
Não Árvores	1698	71604	97,68%
	99,21%	94,30%	97,92%

Tabela 104 - RNA020_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212725	3732	98,28%
Não Árvores	1692	71610	97,69%
	99,21%	95,05%	98,13%

Tabela 105 - RNA025_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212231	4226	98,05%
Não Árvores	1604	71698	97,81%
	99,25%	94,43%	97,99%

Tabela 106 - RNA030_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212391	4066	98,12%
Não Árvores	1619	71683	97,79%
	99,24%	94,63%	98,04%

Tabela 107 - RNA035_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212231	4226	98,05%
Não Árvores	1556	71746	97,88%
	99,27%	94,44%	98,00%

Tabela 108 - RNA040_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212473	3984	98,16%
Não Árvores	1505	71797	97,95%
	99,30%	94,74%	98,11%

Tabela 109 - RNA045_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212577	3880	98,21%
Não Árvores	1605	71697	97,81%
	99,25%	94,87%	98,11%

Tabela 110 - RNA050_morf.Circ_ALDPAT

	Árvores	Não Árvores	
Árvores	212553	3904	98,20%
Não Árvores	1561	71741	97,87%
	99,27%	94,84%	98,11%

Tabela 111 - RNA005_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	211960	4497	97,92%
Não Árvores	1678	71624	97,71%
	99,21%	94,09%	97,87%

Tabela 112 - RNA010_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212169	4288	98,02%
Não Árvores	1627	71675	97,78%
	99,24%	94,36%	97,96%

Tabela 113 - RNA015_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212284	4173	98,07%
Não Árvores	1680	71622	97,71%
	99,21%	94,49%	97,98%

Tabela 114 - RNA020_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212357	4100	98,11%
Não Árvores	1656	71646	97,74%
	99,23%	94,59%	98,01%

Tabela 115 - RNA025_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212657	3800	98,24%
Não Árvores	1654	71648	97,74%
	99,23%	94,96%	98,12%

Tabela 116 - RNA030_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212454	4003	98,15%
Não Árvores	1522	71780	97,92%
	99,29%	94,72%	98,09%

Tabela 117 - RNA035_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212524	3933	98,18%
Não Árvores	1680	71622	97,71%
	99,22%	94,79%	98,06%

Tabela 118 - RNA040_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212437	4020	98,14%
Não Árvores	1553	71749	97,88%
	99,27%	94,69%	98,08%

Tabela 119 - RNA045_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212136	4321	98,00%
Não Árvores	1447	71855	98,03%
	99,32%	94,33%	98,01%

Tabela 120 - RNA050_morf.Linear_ALDPAT

	Árvores	Não Árvores	
Árvores	212616	3841	98,23%
Não Árvores	1657	71645	97,74%
	99,23%	94,91%	98,10%

Tabela 121 - RNA005_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212106	4351	97,99%
Não Árvores	1902	71400	97,41%
	99,11%	94,26%	97,84%

Tabela 122 - RNA010_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212129	4328	98,00%
Não Árvores	1730	71572	97,64%
	99,19%	94,30%	97,91%

Tabela 123 - RNA015_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212099	4358	97,99%
Não Árvores	1696	71606	97,69%
	99,21%	94,26%	97,91%

Tabela 124 - RNA020_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212227	4230	98,05%
Não Árvores	1631	71671	97,77%
	99,24%	94,43%	97,98%

Tabela 125 - RNA025_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212207	4250	98,04%
Não Árvores	1629	71673	97,78%
	99,24%	94,40%	97,97%

Tabela 126 - RNA030_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212203	4254	98,03%
Não Árvores	1565	71737	97,86%
	99,27%	94,40%	97,99%

Tabela 127 - RNA035_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212142	4315	98,01%
Não Árvores	1590	71712	97,83%
	99,26%	94,32%	97,96%

Tabela 128 - RNA040_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212315	4142	98,09%
Não Árvores	1552	71750	97,88%
	99,27%	94,54%	98,03%

Tabela 129 - RNA045_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212397	4060	98,12%
Não Árvores	1641	71661	97,76%
	99,23%	94,64%	98,03%

Tabela 130 - RNA050_morf.Quad._ALDPAT

	Árvores	Não Árvores	
Árvores	212311	4146	98,08%
Não Árvores	1562	71740	97,87%
	99,27%	94,54%	98,03%

Tabela 131 - RNA005_morf.Circ

	Árvores	Não Árvores	
Árvores	211644	4813	97,78%
Não Árvores	1660	71642	97,74%
	99,22%	93,70%	97,77%

Tabela 132 - RNA010_morf.Circ

	Árvores	Não Árvores	
Árvores	212664	3793	98,25%
Não Árvores	1877	71425	97,44%
	99,13%	94,96%	98,04%

Tabela 133 - RNA015_morf.Circ

	Árvores	Não Árvores	
Árvores	212580	3877	98,21%
Não Árvores	1752	71550	97,61%
	99,18%	94,86%	98,06%

Tabela 134 - RNA020_morf.Circ

	Árvores	Não Árvores	
Árvores	212315	4142	98,09%
Não Árvores	1644	71658	97,76%
	99,23%	94,54%	98,00%

Tabela 135 - RNA025_morf.Circ

	Árvores	Não Árvores	
Árvores	212882	3575	98,35%
Não Árvores	1846	71456	97,48%
	99,14%	95,24%	98,13%

Tabela 136 - RNA030_morf.Circ

	Árvores	Não Árvores	
Árvores	212334	4123	98,10%
Não Árvores	1630	71672	97,78%
	99,24%	94,56%	98,01%

Tabela 137 - RNA035_morf.Circ

	Árvores	Não Árvores	
Árvores	212483	3974	98,16%
Não Árvores	1569	71733	97,86%
	99,27%	94,75%	98,09%

Tabela 138 - RNA040_morf.Circ

	Árvores	Não Árvores	
Árvores	212363	4094	98,11%
Não Árvores	1580	71722	97,84%
	99,26%	94,60%	98,04%

Tabela 139 - RNA045_morf.Circ

	Árvores	Não Árvores	
Árvores	212452	4005	98,15%
Não Árvores	1784	71518	97,57%
	99,17%	94,70%	98,00%

Tabela 140 - RNA050_morf.Circ

	Árvores	Não Árvores	
Árvores	212691	3766	98,26%
Não Árvores	1631	71671	97,77%
	99,24%	95,01%	98,14%

Tabela 141 - RNA005_morf.Linear

	Árvore	Não Árvore	
Árvore	211674	4783	97,79%
Não Árvore	1750	71552	97,61%
	99,18%	93,73%	97,75%

Tabela 142 - RNA010_morf.Linear

	Árvore	Não Árvore	
Árvore	211961	4496	97,92%
Não Árvore	1721	71581	97,65%
	99,19%	94,09%	97,85%

Tabela 143 - RNA015_morf.Linear

	Árvore	Não Árvore	
Árvore	212392	4065	98,12%
Não Árvore	1872	71430	97,45%
	99,13%	94,62%	97,95%

Tabela 144 - RNA020_morf.Linear

	Árvore	Não Árvore	
Árvore	212148	4309	98,01%
Não Árvore	1638	71664	97,77%
	99,23%	94,33%	97,95%

Tabela 145 - RNA025_morf.Linear

	Árvore	Não Árvore	
Árvore	212088	4369	97,98%
Não Árvore	1644	71658	97,76%
	99,23%	94,25%	97,92%

Tabela 146 - RNA030_morf.Linear

	Árvore	Não Árvore	
Árvore	212113	4344	97,99%
Não Árvore	1601	71701	97,82%
	99,25%	94,29%	97,95%

Tabela 147 - RNA035_morf.Linear

	Árvore	Não Árvore	
Árvore	212213	4244	98,04%
Não Árvore	1631	71671	97,77%
	99,24%	94,41%	97,97%

Tabela 148 - RNA040_morf.Linear

	Árvore	Não Árvore	
Árvore	212486	3971	98,17%
Não Árvore	1747	71555	97,62%
	99,18%	94,74%	98,03%

Tabela 149 - RNA045_morf.Linear

	Árvore	Não Árvore	
Árvore	212274	4183	98,07%
Não Árvore	1574	71728	97,85%
	99,26%	94,49%	98,01%

Tabela 150 - RNA050_morf.Linear

	Árvore	Não Árvore	
Árvore	212434	4023	98,14%
Não Árvore	1690	71612	97,69%
	99,21%	94,68%	98,03%

Tabela 151 - RNA005_morf.Quad.

	Árvore	Não Árvore	
Árvore	211950	4507	97,92%
Não Árvore	1742	71560	97,62%
	99,18%	94,07%	97,84%

Tabela 152 - RNA010_morf.Quad.

	Árvore	Não Árvore	
Árvore	212365	4092	98,11%
Não Árvore	1809	71493	97,53%
	99,16%	94,59%	97,96%

Tabela 153 - RNA015_morf.Quad.

	Árvore	Não Árvore	
Árvore	212332	4125	98,09%
Não Árvore	1648	71654	97,75%
	99,23%	94,56%	98,01%

Tabela 154 - RNA020_morf.Quad.

	Árvore	Não Árvore	
Árvore	212080	4377	97,98%
Não Árvore	1719	71583	97,65%
	99,20%	94,24%	97,90%

Tabela 155 - RNA025_morf.Quad.

	Árvore	Não Árvore	
Árvore	212553	3904	98,20%
Não Árvore	1752	71550	97,61%
	99,18%	94,83%	98,05%

Tabela 156 - RNA030_morf.Quad.

	Árvore	Não Árvore	
Árvore	212199	4258	98,03%
Não Árvore	1574	71728	97,85%
	99,26%	94,40%	97,99%

Tabela 157 - RNA035_morf.Quad.

	Árvore	Não Árvore	
Árvore	212106	4351	97,99%
Não Árvore	1574	71728	97,85%
	99,26%	94,28%	97,96%

Tabela 158 - RNA040_morf.Quad.

	Árvore	Não Árvore	
Árvore	212514	3943	98,18%
Não Árvore	1644	71658	97,76%
	99,23%	94,78%	98,07%

Tabela 159 - RNA045_morf.Quad.

	Árvore	Não Árvore	
Árvore	212398	4059	98,12%
Não Árvore	1668	71634	97,72%
	99,22%	94,64%	98,02%

Tabela 160 - RNA050_morf.Quad.

	Árvore	Não Árvore	
Árvore	212608	3849	98,22%
Não Árvore	1718	71584	97,66%
	99,20%	94,90%	98,08%

Tabela 161 - RNA005 TIN

	Árvores	Não Árvores	
Árvores	212057	4400	97,97%
Não Árvores	1641	71661	97,76%
	99,23%	94,22%	97,92%

Tabela 162 - RNA010 TIN

	Árvores	Não Árvores	
Árvores	212761	3696	98,29%
Não Árvores	1912	71390	97,39%
	99,11%	95,08%	98,06%

Tabela 163 - RNA015 TIN

	Árvores	Não Árvores	
Árvores	212528	3929	98,18%
Não Árvores	1774	71528	97,58%
	99,17%	94,79%	98,03%

Tabela 164 - RNA020 TIN

	Árvores	Não Árvores	
Árvores	212522	3935	98,18%
Não Árvores	1748	71554	97,62%
	99,18%	94,79%	98,04%

Tabela 165 - RNA025 TIN

	Árvores	Não Árvores	
Árvores	212447	4010	98,15%
Não Árvores	1569	71733	97,86%
	99,27%	94,71%	98,07%

Tabela 166 - RNA030 TIN

	Árvores	Não Árvores	
Árvores	212473	3984	98,16%
Não Árvores	1691	71611	97,69%
	99,21%	94,73%	98,04%

Tabela 167 - RNA035 TIN

	Árvores	Não Árvores	
Árvores	212712	3745	98,27%
Não Árvores	1663	71639	97,73%
	99,22%	95,03%	98,13%

Tabela 168 - RNA040 TIN

	Árvores	Não Árvores	
Árvores	212567	3890	98,20%
Não Árvores	1564	71738	97,87%
	99,27%	94,86%	98,12%

Tabela 169 - RNA045 TIN

	Árvores	Não Árvores	
Árvores	212878	3579	98,35%
Não Árvores	1711	71591	97,67%
	99,20%	95,24%	98,17%

Tabela 170 - RNA050 TIN

	Árvores	Não Árvores	
Árvores	212602	3855	98,22%
Não Árvores	1573	71729	97,85%
	99,27%	94,90%	98,13%

Tabela 171 - RNA005 ETEW

	Árvores	Não Árvores	
Árvores	211949	4508	97,92%
Não Árvores	1660	71642	97,74%
	99,22%	94,08%	97,87%

Tabela 172 - RNA010 ETEW

	Árvores	Não Árvores	
Árvores	211973	4484	97,93%
Não Árvores	1571	71731	97,86%
	99,26%	94,12%	97,91%

Tabela 173 - RNA015 ETEW

	Árvores	Não Árvores	
Árvores	212436	4021	98,14%
Não Árvores	1679	71623	97,71%
	99,22%	94,68%	98,03%

Tabela 174 - RNA020 ETEW

	Árvores	Não Árvores	
Árvores	212280	4177	98,07%
Não Árvores	1552	71750	97,88%
	99,27%	94,50%	98,02%

Tabela 175 - RNA025 ETEW

	Árvores	Não Árvores	
Árvores	212384	4073	98,12%
Não Árvores	1658	71644	97,74%
	99,23%	94,62%	98,02%

Tabela 176 - RNA030 ETEW

	Árvores	Não Árvores	
Árvores	212374	4083	98,11%
Não Árvores	1558	71744	97,87%
	99,27%	94,62%	98,05%

Tabela 177 - RNA035 ETEW

	Árvores	Não Árvores	
Árvores	212603	3854	98,22%
Não Árvores	1647	71655	97,75%
	99,23%	94,90%	98,10%

Tabela 178 - RNA040 ETEW

	Árvores	Não Árvores	
Árvores	212362	4095	98,11%
Não Árvores	1548	71754	97,89%
	99,28%	94,60%	98,05%

Tabela 179 - RNA045 ETEW

	Árvores	Não Árvores	
Árvores	212616	3841	98,23%
Não Árvores	1614	71688	97,80%
	99,25%	94,91%	98,12%

Tabela 180 - RNA050 ETEW

	Árvores	Não Árvores	
Árvores	212706	3751	98,27%
Não Árvores	1613	71689	97,80%
	99,25%	95,03%	98,15%

Tabela 181 - RNA005 Declividade

	Árvores	Não Árvores	
Árvores	211680	4777	97,79%
Não Árvores	1643	71659	97,76%
	99,23%	93,75%	97,78%

Tabela 182 - RNA010 Declividade

	Árvores	Não Árvores	
Árvores	212178	4279	98,02%
Não Árvores	1785	71517	97,56%
	99,17%	94,35%	97,91%

Tabela 183 - RNA015 Declividade

	Árvores	Não Árvores	
Árvores	212531	3926	98,19%
Não Árvores	1907	71395	97,40%
	99,11%	94,79%	97,99%

Tabela 184 - RNA020 Declividade

	Árvores	Não Árvores	
Árvores	211977	4480	97,93%
Não Árvores	1663	71639	97,73%
	99,22%	94,11%	97,88%

Tabela 185 - RNA025 Declividade

	Árvores	Não Árvores	
Árvores	212580	3877	98,21%
Não Árvores	1686	71616	97,70%
	99,21%	94,86%	98,08%

Tabela 186 - RNA030 Declividade

	Árvores	Não Árvores	
Árvores	212539	3918	98,19%
Não Árvores	1733	71569	97,64%
	99,19%	94,81%	98,05%

Tabela 187 - RNA035 Declividade

	Árvores	Não Árvores	
Árvores	212035	4422	97,96%
Não Árvores	1369	71933	98,13%
	99,36%	94,21%	98,00%

Tabela 188 - RNA040 Declividade

	Árvores	Não Árvores	
Árvores	212482	3975	98,16%
Não Árvores	1636	71666	97,77%
	99,24%	94,74%	98,06%

Tabela 189 - RNA045 Declividade

	Árvores	Não Árvores	
Árvores	212342	4115	98,10%
Não Árvores	1528	71774	97,92%
	99,29%	94,58%	98,05%

Tabela 190 - RNA050 Declividade

	Árvores	Não Árvores	
Árvores	212607	3850	98,22%
Não Árvores	1614	71688	97,80%
	99,25%	94,90%	98,11%

Tabela 191 - RNA005 Pirâmide

	Árvores	Não Árvores	
Árvores	179204	37253	82,79%
Não Árvores	963	72339	98,69%
	99,47%	66,01%	86,81%

Tabela 192 - RNA010 Pirâmide

	Árvores	Não Árvores	
Árvores	178609	37848	82,51%
Não Árvores	896	72406	98,78%
	99,50%	65,67%	86,63%

Tabela 193 - RNA015 Pirâmide

	Árvores	Não Árvores	
Árvores	179566	36891	82,96%
Não Árvores	714	72588	99,03%
	99,60%	66,30%	87,02%

Tabela 194 - RNA020 Pirâmide

	Árvores	Não Árvores	
Árvores	180777	35680	83,52%
Não Árvores	527	72775	99,28%
	99,71%	67,10%	87,50%

Tabela 195 - RNA025 Pirâmide

	Árvores	Não Árvores	
Árvores	188647	27810	87,15%
Não Árvores	836	72466	98,86%
	99,56%	72,27%	90,11%

Tabela 196 - RNA030 Pirâmide

	Árvores	Não Árvores	
Árvores	180519	35938	83,40%
Não Árvores	678	72624	99,08%
	99,63%	66,90%	87,36%

Tabela 197 - RNA035 Pirâmide

	Árvores	Não Árvores	
Árvores	178007	38450	82,24%
Não Árvores	605	72697	99,17%
	99,66%	65,41%	86,52%

Tabela 198 - RNA040 Pirâmide

	Árvores	Não Árvores	
Árvores	181335	35122	83,77%
Não Árvores	676	72626	99,08%
	99,63%	67,40%	87,65%

Tabela 199 - RNA045 Pirâmide

	Árvores	Não Árvores	
Árvores	189125	27332	87,37%
Não Árvores	957	72345	98,69%
	99,50%	72,58%	90,24%

Tabela 200 - RNA050 Pirâmide

	Árvores	Não Árvores	
Árvores	188545	27912	87,11%
Não Árvores	1110	72192	98,49%
	99,41%	72,12%	89,98%

APÊNDICE I - Imagem dos Resultados da Filtragem das Árvores (Modelos Digitais de Superfície Urbana – MDSu), dos classificadores Redes Neurais Artificiais e *Support Vector Machine*, com treinamento de 5% e 50%, e métodos de filtragem, para a Área do Centro Politécnico - UFPR, Curitiba - PR




Figura G1 – Imagem dos Modelos Digitais de Superfície Urbana, utilizando 5% de amostras de treinamento para RNA, para cada Método de Filtragem: (a) ETEW; (b) morfqc; (c) morfCALDPAT; (d) morfI; (e) morfLALDPAT; (f) morfqr; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.




Figura G2 – Imagem dos Modelos Digitais de Superfície Urbana, utilizando 50% de amostras de treinamento para RNA, para cada Método de Filtragem: (a) ETEW; (b) morfrc; (c) morfCALDPAT; (d) morfI; (e) morfLALDPAT; (f) morfQ; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.




Figura G3 – Imagem dos Modelos Digitais de Superfície Urbana, utilizando 5% de amostras de treinamento para SVM, para cada Método de Filtragem: (a) ETEW; (b) morfrc; (c) morfCALDPAT; (d) morfI; (e) morfLALDPAT; (f) morfqr; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.




Figura G4 – Imagem dos Modelos Digitais de Superfície Urbana, utilizando 50% de amostras de treinamento para SVM, para cada Método de Filtragem: (a) ETEW; (b) morfrc; (c) morfCALDPAT; (d) morfI; (e) morfLALDPAT; (f) morfQ; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.

APÊNDICE J - Imagem dos Resultados da Filtragem das Árvores (Modelos Digitais de Superfície Urbana – MDSu), dos classificadores Redes Neurais Artificiais e *Support Vector Machine*, com treinamento de 5% e 50%, e métodos de filtragem, para a Área da Água Verde – Rebouças, Curitiba - PR

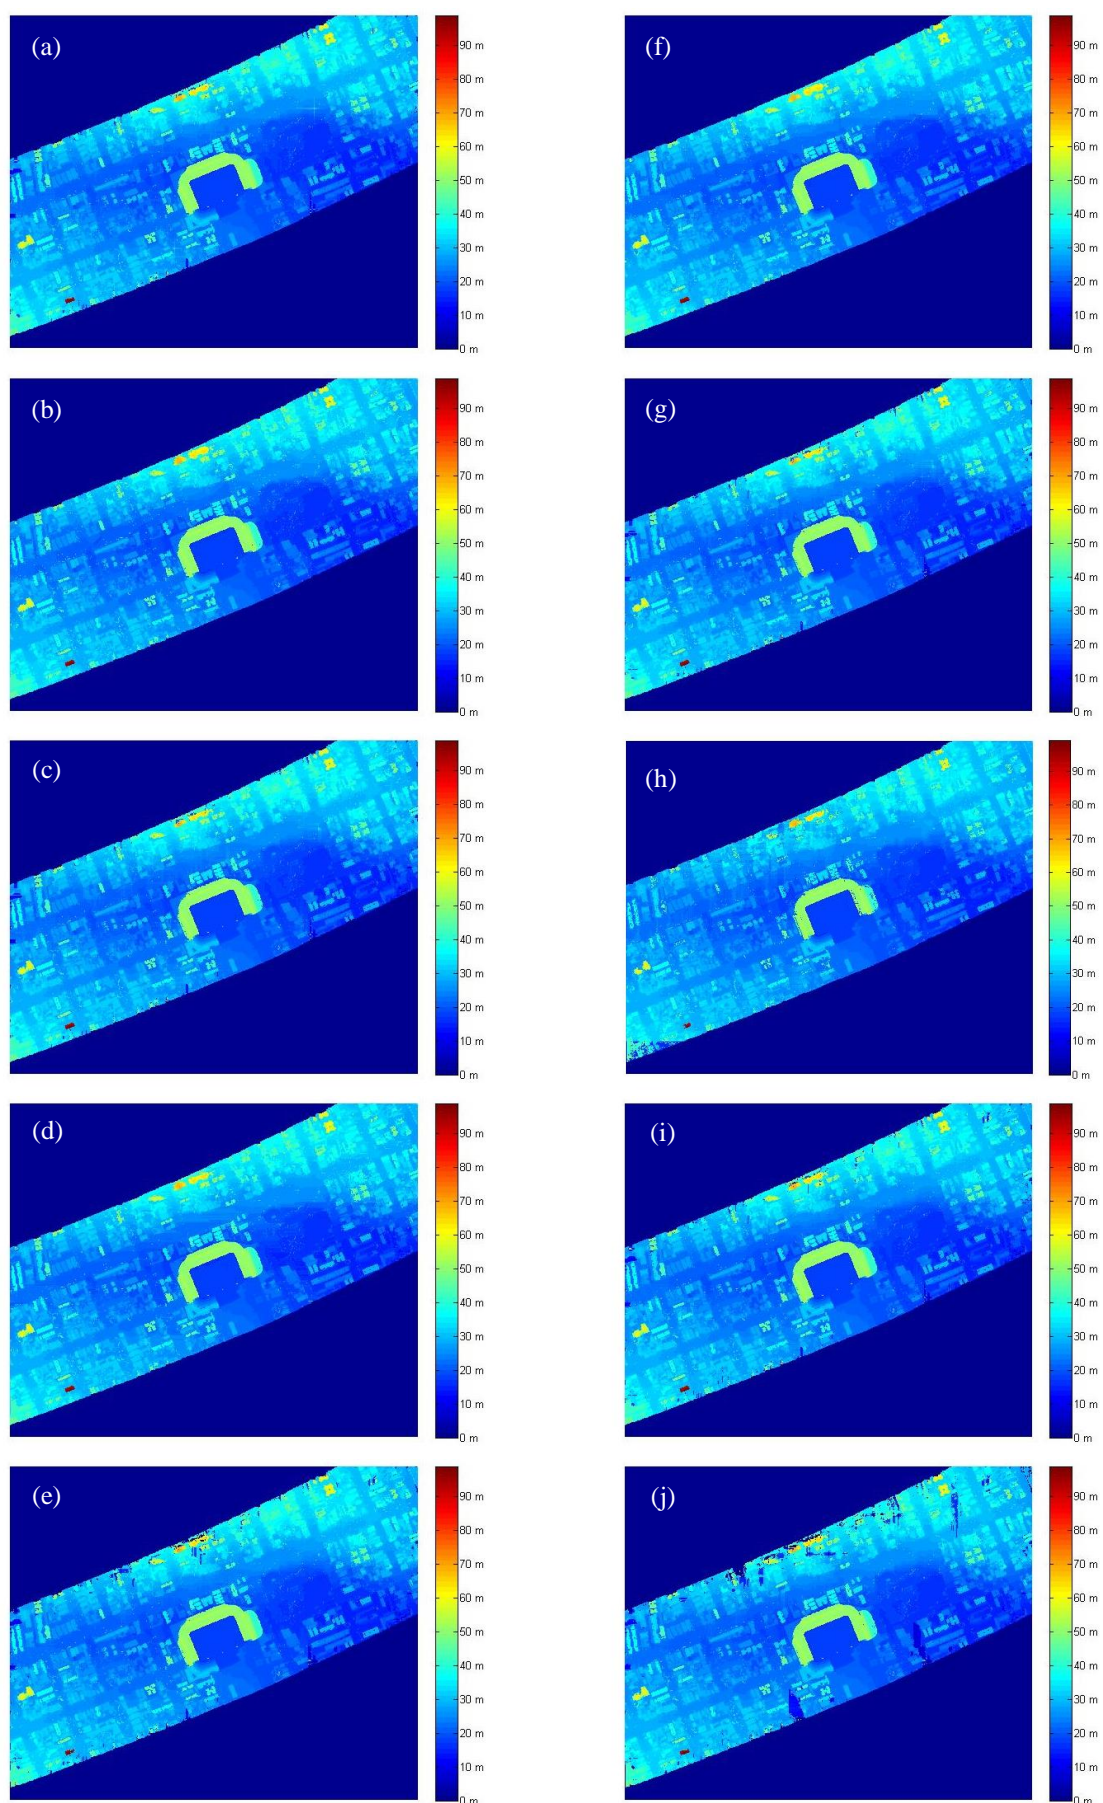


Figura H1 – Imagem dos Modelos Digitais de Superfície Urbana, utilizando 5% de amostras de treinamento para RNA, para cada Método de Filtragem: (a) ETEW; (b) morfC; (c) morfCALDPAT; (d) morfL; (e) morfLALDPAT; (f) morfQ; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.

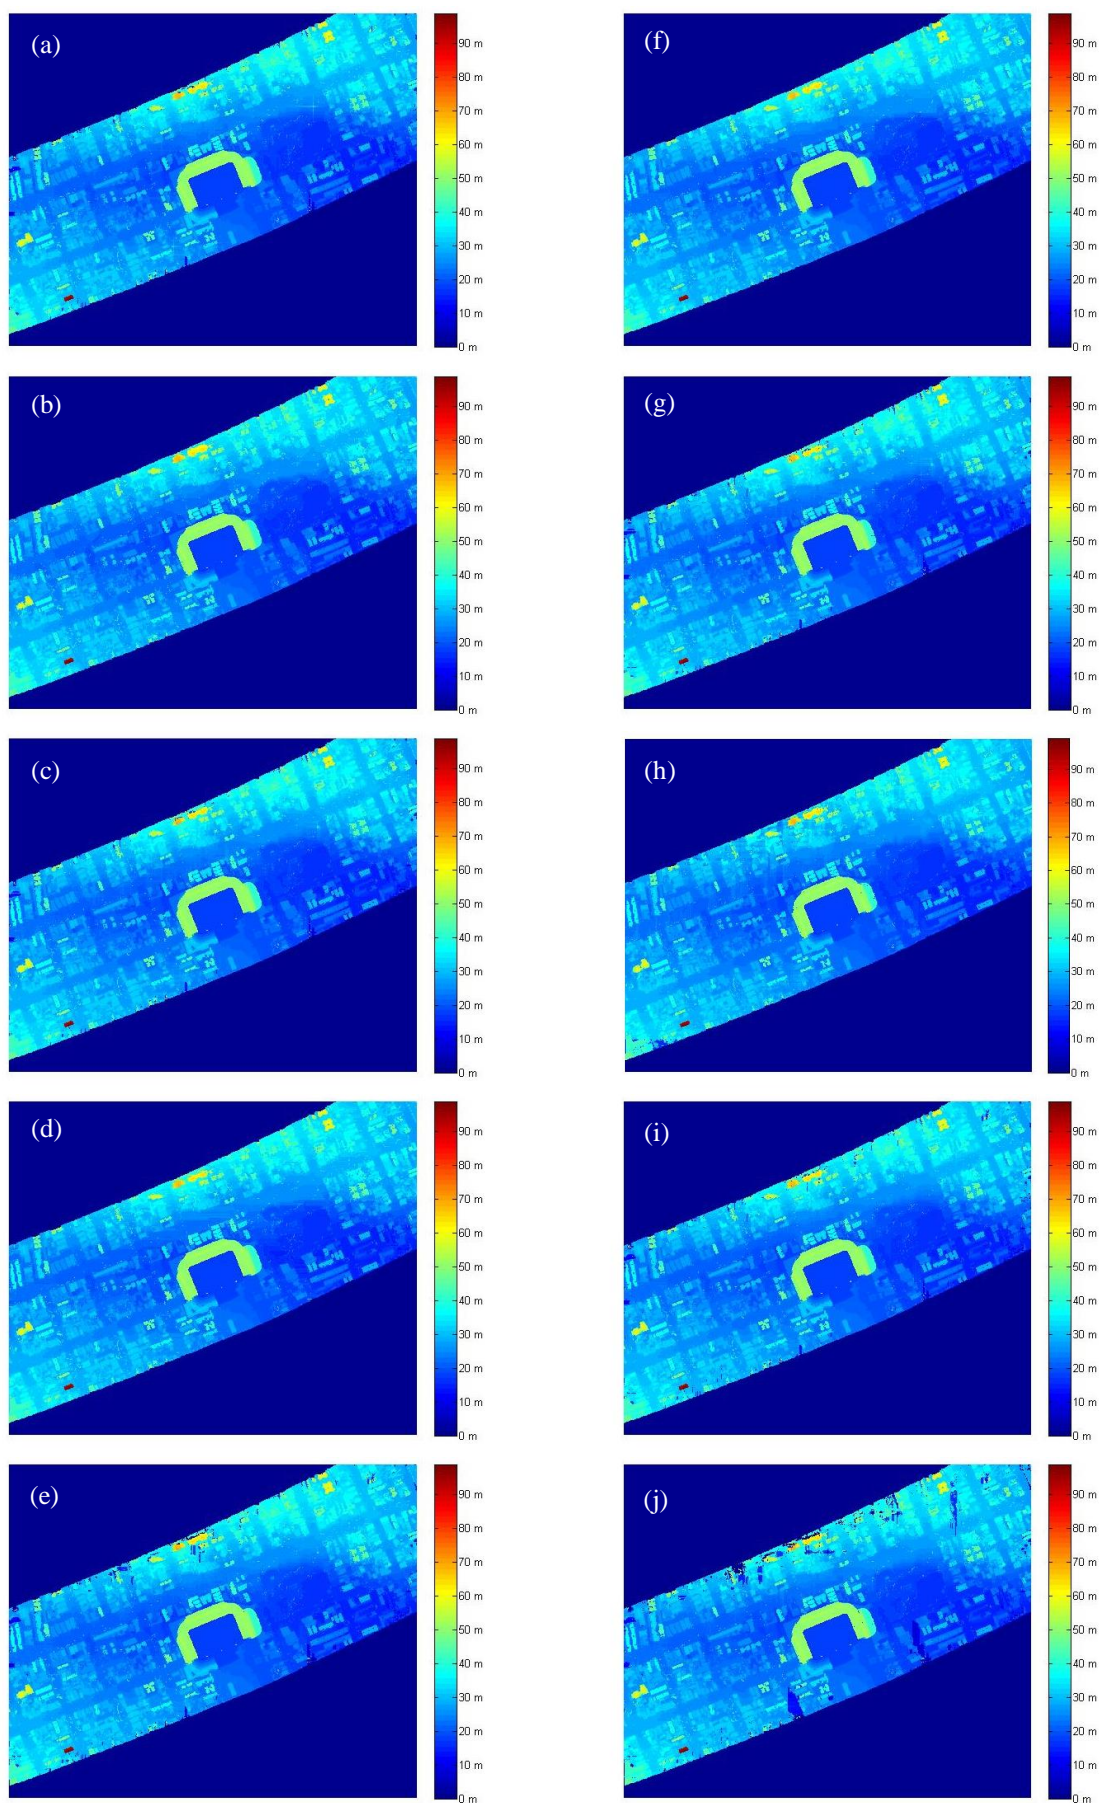


Figura H2 – Imagem dos Modelos Digitais de Superfície Urbana, utilizando 50% de amostras de treinamento para RNA, para cada Método de Filtragem: (a) ETEW; (b) morf_c; (c) morf_{CALDPAT}; (d) morf_l; (e) morf_{LALDPAT}; (f) morf_q; (g) morf_{QALDPAT}; (h) Pirâmide; (i) Declividade; (j) TIN.

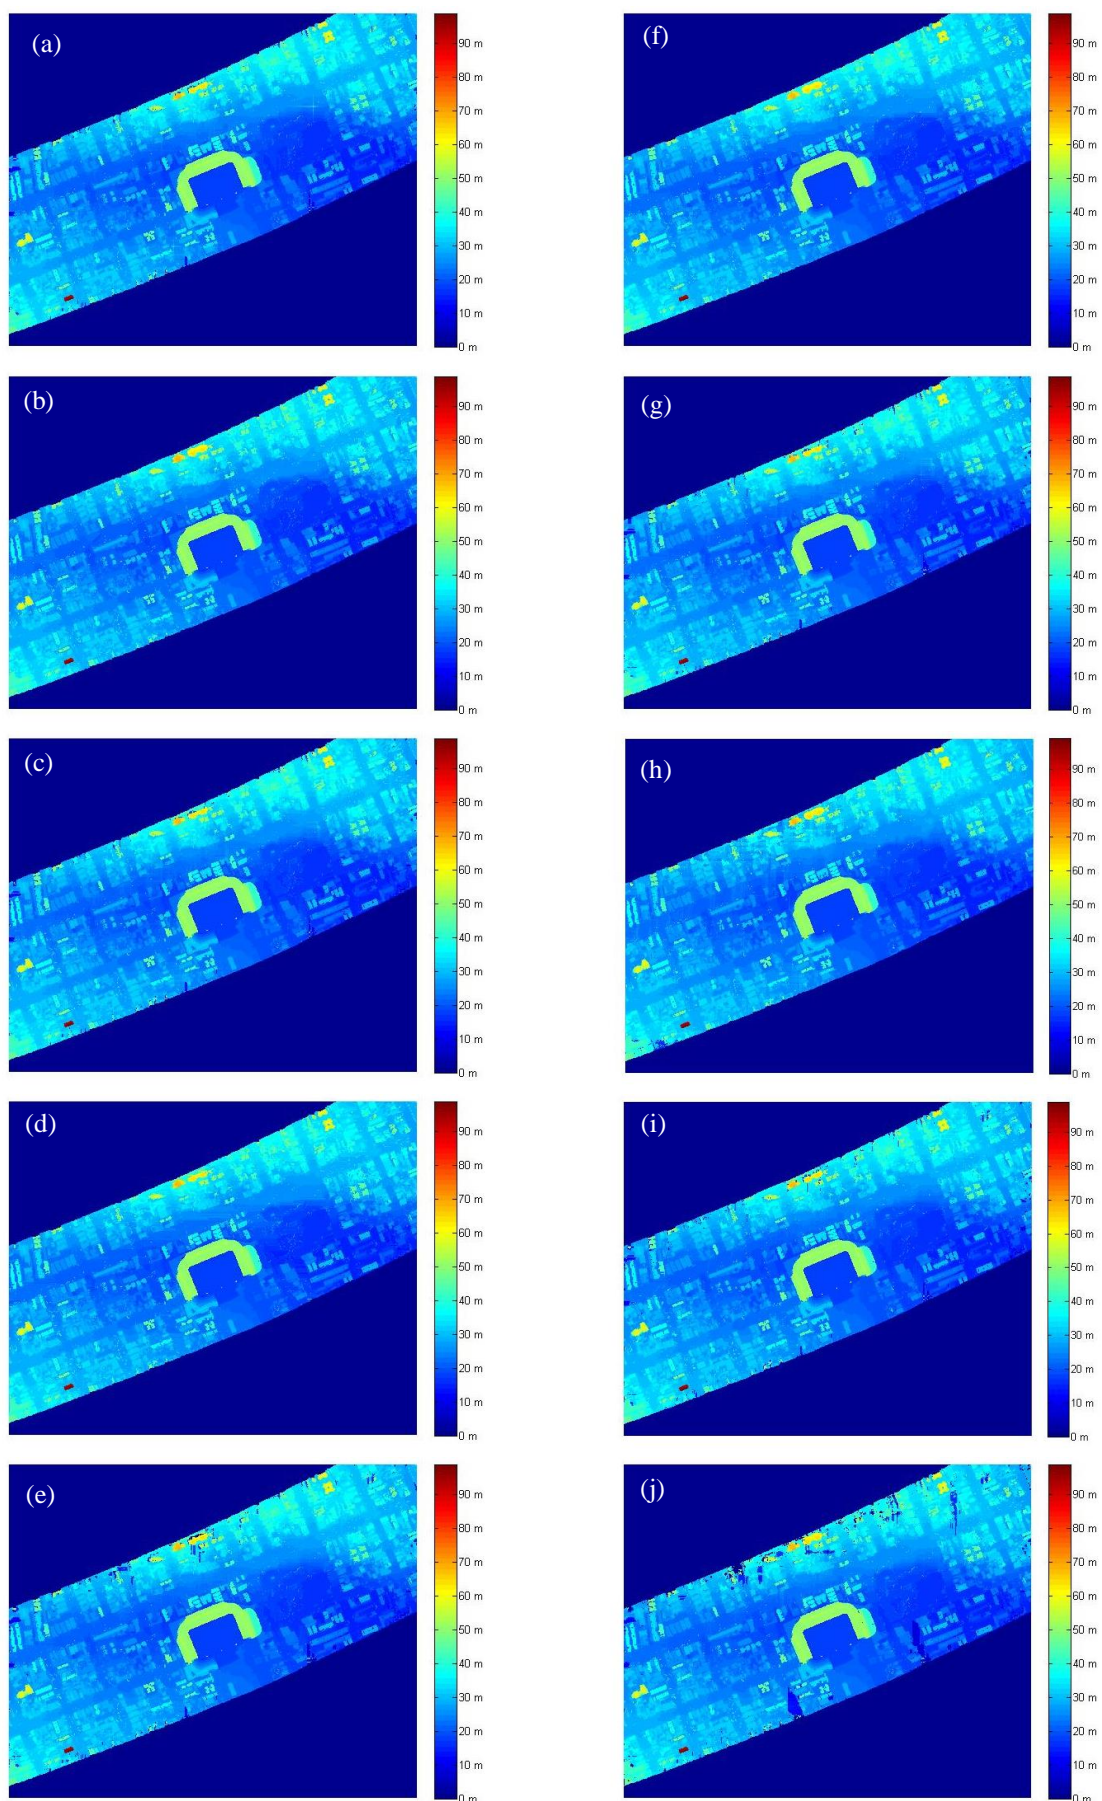


Figura H3 – Imagem dos Modelos Digitais de Superfície Urbana, utilizando 5% de amostras de treinamento para SVM, para cada Método de Filtragem: (a) ETEW; (b) morfC; (c) morfCALDPAT; (d) morfI; (e) morfLALDPAT; (f) morfQ; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.

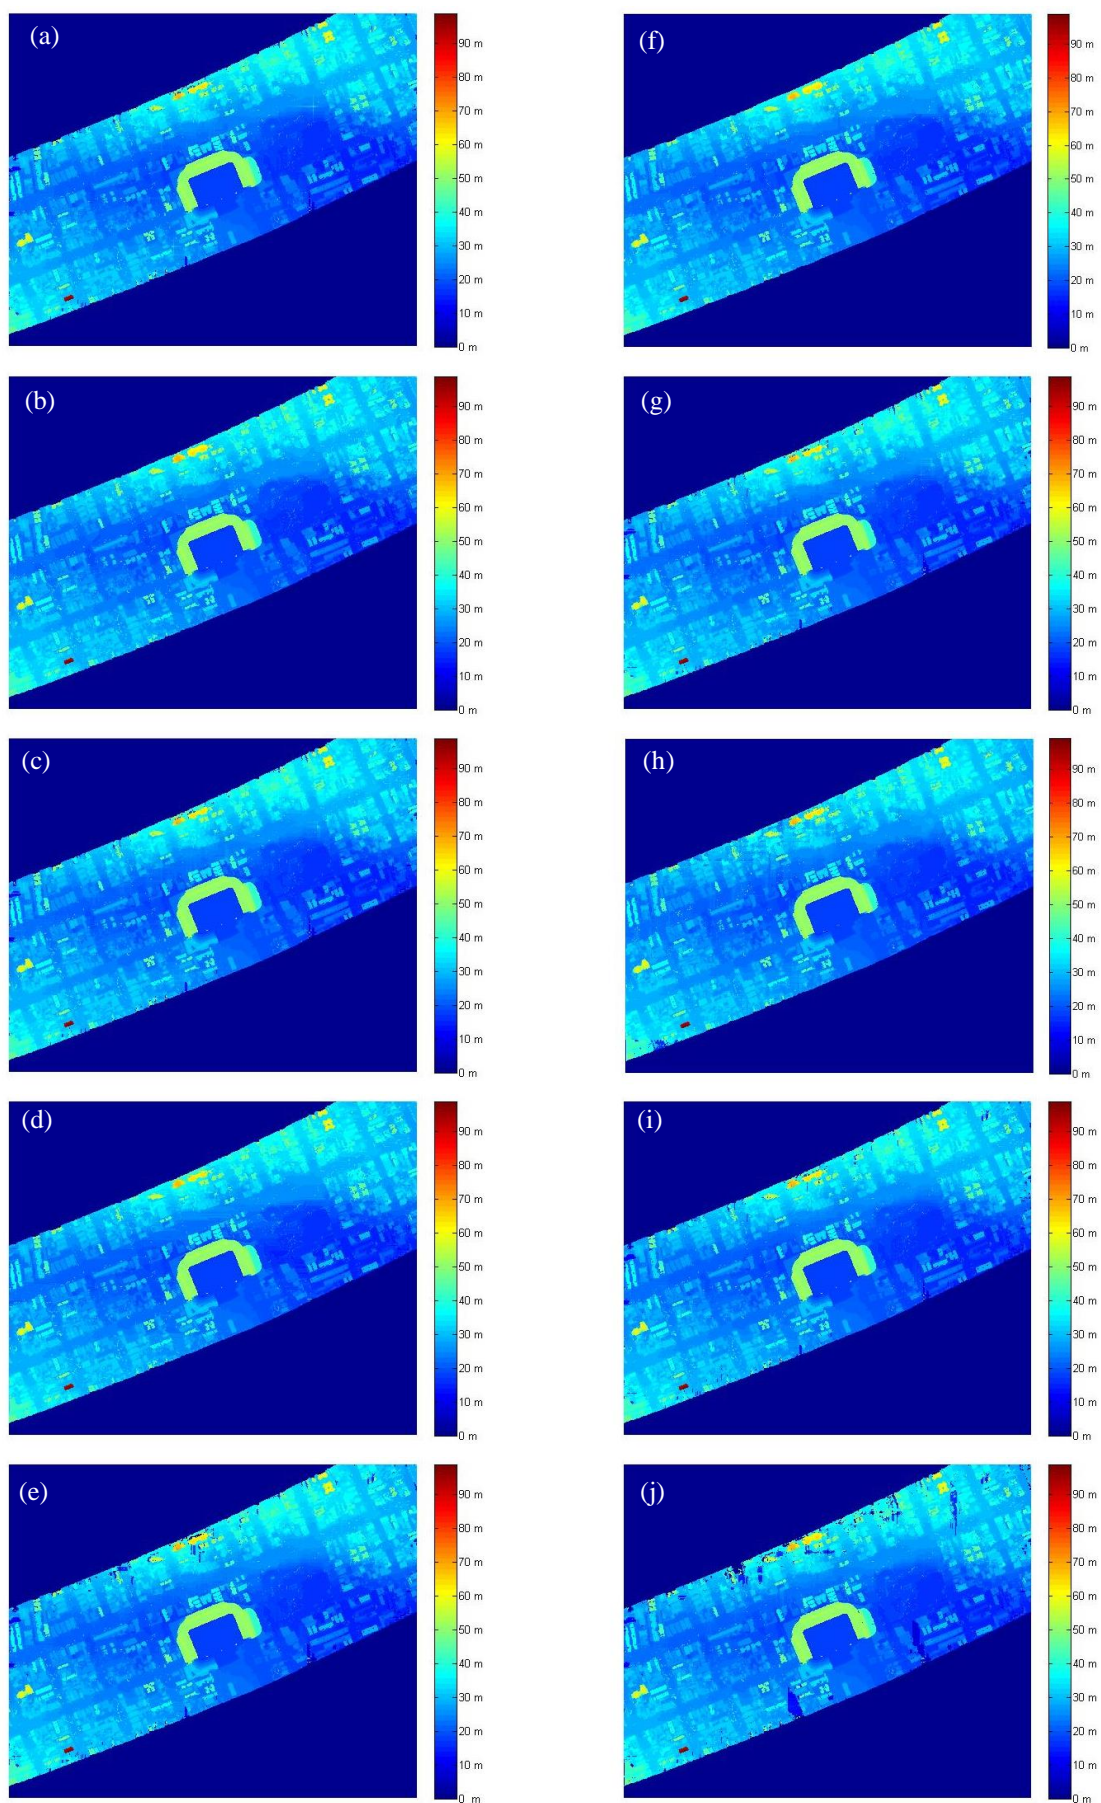


Figura H4 – Imagem dos Modelos Digitais de Superfície Urbana, utilizando 50% de amostras de treinamento para SVM, para cada Método de Filtragem: (a) ETEW; (b) morfC; (c) morfCALDPAT; (d) morfL; (e) morfLALDPAT; (f) morfQ; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.

APÊNDICE K - Imagem dos Resultados dos Modelos de Simulação de Escoamento
Superficial sobre os Modelos Digitais de Superfície Urbana (MDSu) da Área do Centro
Politécnico - UFPR, Curitiba - PR




Figura I1- Imagem dos Resultados do Modelo D8 sobre o MDS, após a Filtragem das Árvores com SVM 50%, para cada Método de Filtragem: (a) ETEW; (b) morf_{fc}; (c) morf_{CALDPAT}; (d) morf_l; (e) morf_{LALDPAT}; (f) morf_q; (g) morf_{QALDPAT}; (h) Pirâmide; (i) Declividade; (j) TIN.




Figura I2- Imagem dos Resultados do Modelo Rh8 sobre o MDS, após a Filtragem das Árvores com SVM 50%, para cada Método de Filtragem: (a) ETEW; (b) morfc; (c) morfCALDPAT; (d) morfl; (e) morflALDPAT; (f) morfq; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.




Figura I3- Imagem dos Resultados do Modelo MS sobre o MDS, após a Filtragem das Árvores com SVM 50%, para cada Método de Filtragem: (a) ETEW; (b) morfc; (c) morfCALDPAT; (d) morfl; (e) morflALDPAT; (f) morfq; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.




Figura I4- Imagem dos Resultados do Modelo FRh8 sobre o MDS, após a Filtragem das Árvores com SVM 50%, para cada Método de Filtragem: (a) ETEW; (b) morf_{fc}; (c) morf_{CALDPAT}; (d) morf_l; (e) morf_{LALDPAT}; (f) morf_q; (g) morf_{QALDPAT}; (h) Pirâmide; (i) Declividade; (j) TIN.




Figura I5- Imagem dos Resultados do Modelo Dinfinite sobre o MDS, após a Filtragem das Árvores com SVM 50%, para cada Método de Filtragem: (a) ETEW; (b) morf_{fc}; (c) morf_{CALDPAT}; (d) morf_{fl}; (e) morf_{LALDPAT}; (f) morf_{fq}; (g) morf_{QALDPAT}; (h) Pirâmide; (i) Declividade; (j) TIN.

APÊNDICE L - Imagem dos Resultados dos Modelos de Simulação de Escoamento Superficial sobre os Modelos Digitais de Superfície Urbana (MDSu) da Área da Água Verde – Rebouças, Curitiba - PR




Figura J1- Imagem dos Resultados do Modelo D8 sobre o MDS, após a Filtragem das Árvores com SVM 50%, para cada Método de Filtragem: (a) ETEW; (b) morf;c; (c) morfCALDPAT; (d) morf;l; (e) morfLALDPAT; (f) morf;q; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.




Figura J2- Imagem dos Resultados do Modelo Rh8 sobre o MDS, após a Filtragem das Árvores com SVM 50%, para cada Método de Filtragem: (a) ETEW; (b) morfc; (c) morfCALDPAT; (d) morfl; (e) morflALDPAT; (f) morfqq; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.




Figura J3- Imagem dos Resultados do Modelo MS sobre o MDS, após a Filtragem das Árvores com SVM 50%, para cada Método de Filtragem: (a) ETEW; (b) morf;c; (c) morfCALDPAT; (d) morf;l; (e) morfLALDPAT; (f) morf;q; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.




Figura J4- Imagem dos Resultados do Modelo FRh8 sobre o MDS, após a Filtragem das Árvores com SVM 50%, para cada Método de Filtragem: (a) ETEW; (b) morf;c; (c) morfCALDPAT; (d) morf;l; (e) morfLALDPAT; (f) morf;q; (g) morfQALDPAT; (h) Pirâmide; (i) Declividade; (j) TIN.




Figura J5- Imagem dos Resultados do Modelo Dinfinite sobre o MDS, após a Filtragem das Árvores com SVM 50%, para cada Método de Filtragem: (a) ETEW; (b) morf_c; (c) morf_{CALDPAT}; (d) morf_I; (e) morf_{LALDPAT}; (f) morf_Q; (g) morf_{QALDPAT}; (h) Pirâmide; (i) Declividade; (j) TIN.